



UNIVERSITÉ SULTAN MOULAY SLIMANE
FACULTÉ DES SCIENCES ET TECHNIQUES
Béni Mellal



Centre des Études Doctorales : Sciences et Techniques.
Formation doctorale : Mathématique et Physique Appliquées.

THÈSE
Présentée par

BRAHIM JABIR

Pour l'obtention du grade de

DOCTEUR

Discipline : Informatique

Spécialité : Informatique

**“Deep Analytics” au service d’une agriculture digitale et de
précision : Application à la détection des mauvaises herbes.**

Soutenue le 24 /03/2022 devant le jury composé de :

Pr. Belaid BOUIKHALENE	PES, Faculté Polydisciplinaire, Béni Mellal-USMS	Président du jury
Pr. Najlae IDRISSE	PES, Faculté des Sciences et Techniques, Béni Mellal-USMS	Rapporteur
Pr. Yassine SADQI	PH, Faculté Polydisciplinaire, Béni Mellal-USMS	Rapporteur
Pr. Ayoub AIT LAHCEN	PH, École Nationale des Sciences Appliquées, Kénitra-UIT	Rapporteur
Pr. Abderrazak FARCHANE	PH, Faculté Polydisciplinaire, Béni Mellal-USMS	Examineur
Pr. Nouredine FALIH	PH, Faculté Polydisciplinaire, Béni Mellal-USMS	Directeur de thèse

Dédicaces

Louange à Dieu tout Puissant, Seigneur de l'univers, le tout Miséricordieux, le tout Clément !

Sans son aide et concours, ce travail n'aurait été accompli.

Je dédie ce travail :

Tout d'abord à ma défunte mère qui a toujours souhaité que je réussisse dans mes études. Qui est malheureusement parti, avant cet événement qu'elle attendait toujours avec impatience et avant que je la veuille, un peu de ce qu'elle m'a donné. Je prie le Tout Puissant ALLAH pour le repos de son âme.

À mon père, qui a cru en moi pendant tout mon parcours, toujours fier de moi et toujours présent avec son soutien. Seigneur, donne-lui longue vie et bonne santé.

À mes frères et sœurs, hommes et femmes, avec qui j'ai partagé chaque instant de ma vie et qui m'ont soutenu dans toutes les étapes de mes études, j'espère que Dieu leur accorde tout ce qu'ils souhaitent.

À mes amis, qui sont plutôt mes frères. Nombreux qu'ils sont, mais je partage véritablement avec eux un sentiment de fraternité, ils n'ont jamais hésité à m'apporter de l'aide.

Remerciements

À l'issue de la rédaction de ce manuscrit de thèse, je suis convaincu que la thèse est loin d'être un travail solitaire. En effet, ce travail doctoral n'aurait jamais pu aboutir sans le soutien d'un grand nombre de personnes dont la générosité, la bonne humeur et l'intérêt manifestés à l'égard de ma recherche m'ont permis de progresser dans cette phase délicate de l'apprenti-chercheur.

Ce n'est pas par simple habitude et tradition que je commence par remercier Monsieur le Professeur **Noureddine FALIH**, directeur de ma Thèse, mais parce que vraiment le grand mérite revient à lui après le Seigneur. Ses qualités intellectuelles et personnelles font de lui un directeur de thèse tout particulier. J'ose dire dans la présente prose, que ces mots que j'écris pour lui ne sont pas flatterie ni par obligation de tradition, mais parce qu'il mérite plus que ces mots, Dieu en témoigne. Il était toujours présent comme le père scientifique pour me mettre en lumière les choix à faire ; preuve de son ouverture intellectuelle et expérience dans la recherche scientifique. Sa culture scientifique, son ouverture d'esprit et sa modestie faisaient de lui un encadrant très particulier. Il discutait toujours avec nous, qui sommes ses étudiants, en nous faisant apprendre, en nous donnant des conseils et sans jamais imposer, cela donnait à lui plus de valeur dans nos cœurs.

Je tiens à remercier également tous les membres du jury d'avoir accepté d'évaluer ce travail, notamment son président **Pr. Belaid BOUIKHALENE**, pour son professionnalisme et savoir-faire. Mes immenses remerciements vont également aux rapporteurs de ma thèse **Pr. Najlae IDRISSE**, **Pr. Ayoub AIT LAHCEN** et **Pr. Yassine SADQI** pour le temps et intérêt alloués à ce travail où leur expertise et perfectionnisme étaient de mise pour améliorer davantage le manuscrit. Je manifeste aussi ma gratitude au **Pr. Abderrazak FARCHANE** qui m'a offert l'honneur d'être examinateur de ma thèse.

Mes remerciements s'adressent également aux membres du laboratoire "LIMATI", pour le soutien moral très particulier, pour l'intérêt dont ils ont fait preuve envers la recherche et le développement de notre laboratoire.

En définitive, je remercie vivement tous ceux qui ont contribué de loin ou de près à ce travail, en l'occurrence tous mes chers collègues du CRMEF Béni Mellal-Khenifra et plus particulièrement son directeur régional **M. Mohamed HABA** pour son soutien et son intérêt permanents à l'égard de mes travaux de recherches.

Merci à vous tous et toutes.

Résumé

L'agriculture digitale est une révolution technologique du domaine agricole qui consiste à digitaliser les processus et filière de l'agriculture, tout en profitant des technologies avancées du digital, en vue de booster la productivité, optimiser les ressources et améliorer la performance, dans le dessein de contribuer efficacement à la sécurité alimentaire. En effet, les technologies de pointe liées à l'intelligence artificielle, Big data Analytics, Cloud Computing et à l'internet des objets constituent le levier d'une agriculture digitale révolutionnaire, permettant une analyse stratégique et prédictive des données agricoles massives collectées (données météorologiques, images des cultures, états des sols, demandes de commercialisation, suivi des terres, etc.), au profit d'une gestion smart et optimale des parcelles agricoles.

Cette thèse vise à ajouter une pierre académique à cet édifice d'agriculture digitale et connectée. Il s'agit particulièrement d'appliquer les algorithmes de deep learning pour la gestion des cultures, notamment pour la détection des mauvaises herbes, en vue d'une meilleure productivité agricole. Ce travail de recherches propose des contributions pragmatiques basées sur un ensemble d'algorithmes susceptibles de renforcer l'Analytics à base de deep learning dans différents problèmes agricoles. En particulier, nous traitons la question de détection des plantes adventices par le biais d'une application informatique assurant l'amélioration du processus d'apprentissage des algorithmes. Nous y partageons, également, les résultats d'un ensemble d'études détaillées autour des approches existantes visant à améliorer les algorithmes de classification et de détection. Les constats dégagés de ces études nous ont inspiré pour proposer un ensemble de méthodes et de solutions susceptibles d'améliorer les modèles d'apprentissage profond au profit de l'agriculture et de l'industrie agroalimentaire. À la lumière de ces résultats, nous proposons un modèle hybride composé d'un réseau de neurones ResNeXt avec Machine à Vecteurs de Support (SVM). Ce modèle s'est avéré consistant et efficace favorisant une meilleure détection des mauvaises herbes pour l'optimisation des cultures et la hausse du rendement agricole. Ce travail se veut également une feuille de route scientifique et dessine de nouveaux sillons pour les futurs doctorants et chercheurs désirant appréhender davantage dans cette doctrine d'agriculture digitale.

Mots-Clés : *Deep Analytics ; Agriculture digitale ; Agriculture 4.0 ; Détection des mauvaises herbes ; Intelligence Artificielle ; Machine Learning ; Deep Learning ; Réseaux de neurones.*

Abstract

Digital agriculture is a technological revolution in the agricultural field which consists of digitizing agricultural processes and sectors, while taking advantage of advanced digital technologies, with a view to boosting productivity, optimizing resources and improving performance, with the aim of contributing effectively to food security. Indeed, advanced technologies related to artificial intelligence, Big data Analytics, Cloud Computing and the Internet of Things constitute the lever of a revolutionary digital agriculture, allowing an analysis strategic and predictive massive agricultural data collected (meteorological data, images of crops, soil conditions, marketing requests, land monitoring, etc.), for the benefit of smart and optimal management of agricultural plots.

This doctoral dissertation aims to add an academic pillar to build a digital and connected agriculture. It is particularly a question of applying deep learning algorithms for crop management, in particular for the detection of weeds, with a view to improving agricultural productivity. This research work offers pragmatic contributions based on a set of algorithms likely to strengthen deep learning-based Analytics in different agricultural problems. In particular, we deal with the issue of weed plant detection through a computer application ensuring the improvement of the algorithm learning process. We also share the results of a set of detailed studies around existing approaches aimed at improving classification and detection algorithms. The findings from these studies have inspired us to propose a set of methods and solutions that can improve deep learning models for the benefit of agriculture and the agri-food industry. In light of these results, we propose a hybrid model composed of a ResNeXt neural network with Support Vector Machine (SVM). This model has proven to be consistent and effective, promoting better weed detection for crop optimization and increasing agricultural yield. This work is also intended to be a scientific roadmap and draws new paths for future doctoral students and researchers wishing to understand more about this doctrine of digital agriculture.

Keywords: *Deep Analytics; Digital agriculture; Agriculture 4.0; Weed detection; Artificial intelligence ; Machine learning; Deep learning; Neural networks.*

Table des matières

Liste des figures -----	10
Liste des tableaux -----	12
Liste des abréviations et sigles -----	13
Introduction générale -----	15
Chapitre I: Revue de littérature: agriculture digitale et de précision	
1. Introduction -----	20
2. Défis agricoles -----	21
2.1 Augmentation de la démographie -----	21
2.2 Changement climatique -----	22
3. Recherches existantes -----	23
4. Agriculture 4.0 et l’agriculture de précision -----	24
4.1 Agriculture basée sur les technologies avancées du Digital -----	25
4.1.2 Cloud Computing en agriculture -----	25
4.1.3 Agricultural Internet of Things (AIoT) -----	27
4.1.4 Big Data Analytics en agriculture -----	28
4.1.5 Intelligence Artificielle appliquée à l’agriculture -----	28
4.2 Benchmark des technologies existantes dans le domaine agricole -----	29
4.3 Domaines de l’agriculture de précision -----	37
4.3.1 Détection des maladies -----	37
4.3.2 Classification des cultures -----	38
4.3.3 Irrigation de précision -----	40
4.3.4 Élevage de précision -----	41
4.3.5 Détection des mauvaises herbes -----	42
4.3.6 Autres filières -----	43
4.4 Agriculture digitale au Maroc -----	43
5. Conclusion -----	45
Chapitre II: Étude et benchmark des techniques et algorithmes de l'intelligence artificielle	
1. Introduction -----	47
2. Intelligence artificielle -----	48
2.1 Machine Learning -----	50
2.2 Deep Learning -----	52
3. Deep Learning pour le traitement de l’image et la vision par ordinateur -----	61
3.1 Classification des images -----	61
3.2 Détection d’objets -----	62

3.3 Segmentation des images -----	64
4. Algorithmes de vision par ordinateur-----	65
4.1 R-CNN -----	66
4.2 Fast R-CNN-----	68
4.3 Faster R-CNN -----	69
4.4 Mask R-CNN -----	70
5. Agriculture intelligente basée sur Deep Learning -----	72
5.1 Applications de Deep Learning dans le domaine agricole -----	74
5.1.1 Domaine des plantes -----	74
5.1.2 Domaine animalier -----	76
5.1.3 Autres domaines -----	77
5.2 Répartition technique-----	78
5.3 Sources de données et métadonnées -----	80
6. Conclusion -----	81
 Chapitre III: Entraînement de quelques modèles de DL open source au profit de la détection des mauvaises herbes	
1. Introduction -----	84
2. Hardware & Software utilisés -----	85
2.1 Tensorflow -----	85
2.2 Keras -----	86
2.3 Python -----	86
2.4 Apprentissage par transfert -----	86
2.5 Configuration matérielle -----	87
3. Étude comparative des modèles de détection d'objets open source -----	87
3.1 Méthodes de détection d'objets basées sur le Deep Learning -----	87
3.2 Argumentaire -----	88
3.3 Architectures -----	89
3.3.1 EfficientDet -----	89
3.3.2 Faster R-CNN -----	89
3.3.3 YOLOv5 -----	90
3.3.4 Detectron2 -----	90
4. Résultats et discussion -----	94
5. Conclusion -----	99

Chapitre IV: Études de cas : amélioration des modèles de CNN pour la détection des mauvaises herbes

1. Introduction -----	102
2. Méthodes et outils -----	103
2.1 Datasets utilisés -----	103
2.2 Environnement matériel -----	104
3. Expérience 1 : CNN pour l'identification des mauvaises herbes -----	105
3.1 Architecture de base -----	105
3.2 Résultats -----	106
4. Expérience 2 : YOLO V5 pour la reconnaissance des adventices -----	111
4.1 Architecture utilisée -----	111
4.2 Résultats -----	112
5. Expérience 3 : CNN basé sur des méthodes de régularisation pour la détection des mauvaises herbes -----	114
5.1 Architecture de DL -----	114
5.2 Résultats -----	116
6. Discussion -----	119
7. Conclusion -----	122

Chapitre V: Proposition d'un modèle hybride de Deep Analytics appliqué à la détection des mauvaises herbes

1. Introduction -----	125
2. Amélioration de la performance de la prédiction obtenue -----	127
2.1 Amélioration de la performance relative aux données -----	127
2.2 Amélioration de la performance basée sur les méthodes d'exploitation -----	135
2.3 Amélioration de la performance issue des réglages du modèle -----	138
2.4 Amélioration de la performance tirée des méthodes ensemblistes -----	140
3. Approche proposée : Modèle hybride ResNeXt-SVM -----	142
3.1 Méthodes et outils -----	143
3.2 Dataset -----	143
3.3 Réseau de neurones ResNeXt -----	144
3.4 Machine à vecteurs de support (SVM) -----	147
3.5 Détection des mauvaises herbes basé sur le modèle hybride proposé -----	149
3.6 Résultats et discussion -----	150
4. Conclusion -----	152
Conclusion générale et perspectives -----	153

Production scientifique -----	157
1. Récapitulatif en chiffres-----	157
2. Articles publiés par des journaux indexés Scopus et/ou WoS-----	157
3. Articles de conférences dont le proceeding est indexé Scopus-----	158
4. Communications internationales avec comité de programme -----	158
5. Chapitre de livre et communication nationale -----	158
Références -----	159

Liste des figures

Chapitre I

Figure 1- 1: Une forte augmentation de la démographie	22
Figure 1- 2: Le changement climatique réduit la productivité de l'agriculture	23
Figure 1- 3: Utilisation des technologies avancées du digital dans l'agriculture	24
Figure 1- 4: Cycle de gestion basé sur l'information pour l'agriculture 4.0.....	25
Figure 1- 5: Utilisation du cloud dans l'agriculture intelligente.....	26
Figure 1- 6: Utilisation IoT agricole	27
Figure 1- 7: Images de quatre maladies du concombre	38
Figure 1- 8: Classification des types de cultures	39
Figure 1- 9: Le cycle de fonctionnement d'un système d'irrigation intelligent.....	40
Figure 1- 10: Systèmes d'élevage de précision.....	41
Figure 1- 11: Détection de mauvaises herbes	43

Chapitre II

Figure 2- 1: Relation entre IA, ML et DL.....	49
Figure 2- 2: Réseau neuronal à perceptron multicouche	53
Figure 2- 3: Architecture standard du réseau de neurones convolutifs.....	55
Figure 2- 4: Convolution d'une image de $5 \times 5 \times 1$ avec un filtre de $3 \times 3 \times 1$	56
Figure 2- 5: Types de Pooling.....	57
Figure 2- 6: (À gauche) Un RNN. (À droite) Sa version déroulée.....	58
Figure 2- 7: Classification des chiffres manuscrits.....	62
Figure 2- 8: Détection des mauvaises herbes utilisant la technique "Object Detection"	63
Figure 2- 9: (a) classification d'images, (b) détection d'objets, (c) segmentation sémantique et (d) segmentation d'instances	65
Figure 2- 10: L'architecture de R-CNN.....	66
Figure 2- 11: L'extraction des caractéristiques.....	67
Figure 2- 12: L'architecture de Fast R-CNN	68
Figure 2- 13: L'architecture de Faster R-CNN	69
Figure 2- 14: L'architecture de Mask R-CNN.....	71
Figure 2- 15: L'architecture dorsale du masque R-CNN.....	72
Figure 2- 16: Les applications les plus répandues du DL en agriculture.....	73
Figure 2- 17: L'utilisation des méthodes d'apprentissage en profondeur dans l'agriculture [77].	73
Figure 2- 18: L'ordre des frameworks de Deep Learning (2020) [139].....	80

Chapitre III

Figure 3- 1: Architecture actuelle d'un réseau de détection d'objets	89
Figure 3- 2: Comparaison de précision sur COCO test-dev	91
Figure 3- 3: Préparation du jeu de données	91
Figure 3- 4: Type 1: Convolvulus - Figure 3- 5: Type 2: Phalaris Paradoxa.....	92
Figure 3- 6: L'annotation des boîtes englobantes des objets dans les images	93
Figure 3- 7: Ensemble de méthodes d'augmentation de données appliquées	94
Figure 3- 8: La performance de l'EfficientDet - Figure 3- 9: Taux d'erreur de l'EfficientDet....	96
Figure 3- 10: Les prédictions sur les images de test	96
Figure 3- 11: La performance de YOLOv5 - Figure 3- 12: Taux d'erreur pour YOLOv5.....	97

Figure 3- 13: La performance de Detectron2 - Figure 3- 14: Taux d'erreur pour Detectron2..... 97
 Figure 3- 15: Performance de Faster R-CNN - Figure 3- 16: Taux d'erreur de Faster R-CNN... 98

Chapitre IV

Figure 4- 1: Architecture du modèle	106
Figure 4- 2: Configuration du modèle	106
Figure 4- 3: Les performances du modèle	107
Figure 4- 4: Le taux d'erreur du modèle	108
Figure 4- 5: Les noms des modèles créées.....	109
Figure 4- 6: Les performances de 80 modèles créés.....	109
Figure 4- 7: Le taux d'erreur pour les 80 modèles.....	110
Figure 4- 8: Trois premiers modèles avec la meilleure performance	110
Figure 4- 9: La performance du modèle amélioré	111
Figure 4- 10: Architecture de DL.....	112
Figure 4- 11: Configuration du modèle	112
Figure 4- 12: Détails du modèle utilisé.....	113
Figure 4- 13: Les performances de notre modèle	113
Figure 4- 14: Architecture du modèle avant la méthode Dropout	115
Figure 4- 15: L'ajout de la méthode Dropout	116
Figure 4- 16: L'accuracy de l'entraînement et de la validation avant le Dropout	117
Figure 4- 17: L'accuracy de l'entraînement et de la validation après le Dropout	118
Figure 4- 18: Vue d'ensemble du système de pulvérisation.....	122

Chapitre V

Figure 5- 1: L'évolution de la performance de DL avec la quantité de données.....	128
Figure 5- 2: La production de nouvelles données en décodant des points échantillonnés	130
Figure 5- 3: Fonctionnement du GAN	131
Figure 5- 4: Le fonctionnement de la méthode Bagging	141
Figure 5- 5: Le jeu de données utilisé dans notre expérience	144
Figure 5- 6: Une vue comparative entre les paramètres de ResNet et ceux de ResNeXt	145
Figure 5- 7: À gauche : Architecture de ResNet et à droite : Architecture de ResNeXt	146
Figure 5- 8: Différents paramètres de modèles de complexité 2×2	146
Figure 5- 9: Le modèle hybride proposé.....	149
Figure 5- 10: Les performances du modèle après l'apprentissage.....	150
Figure 5- 11: Le taux d'erreur du modèle après l'apprentissage	150

Liste des tableaux

Chapitre I

Tableau 1- 1. Intelligence artificielle : Points forts et limites.....	30
Tableau 1- 2. Big data Analytique : Points forts et limites.....	32
Tableau 1- 3. IoT: Points forts et limites	33
Tableau 1- 4. Blockchains : Points forts et limites	35

Chapitre II

Tableau 2- 1. Définitions des termes courants en intelligence artificielle.....	49
Tableau 2- 2. Exemples d'utilisation d'algorithmes	51
Tableau 2- 3. Benchmark des algorithmes de ML et de DL existants	59
Tableau 2- 4. Applications de Deep Learning en agriculture (détection des mauvaises herbes) .	75
Tableau 2- 5. Applications de Deep Learning pour un groupe de problèmes agricoles	77
Tableau 2- 6. Classement des articles analysés selon les techniques DL	79
Tableau 2- 7. Datasets d'images publiques dédiées au DL pour l'agriculture	81

Chapitre III

Tableau 3- 1. Les performances des modèles étudiés.....	98
---	----

Chapitre IV

Tableau 4- 1. Détails des datasets utilisés dans les trois études.....	104
Tableau 4- 2. Les performances avant et après l'amélioration	119

Chapitre V

Tableau 5- 1. Comparaison des résultats obtenus avec ceux de ResNet et ResNeXt.	151
--	-----

Liste des abréviations et sigles

<i>FAO</i>	Food and Agriculture Organization
<i>OCDE</i>	Organisation de Coopération et de Développement Économiques
<i>IT</i>	Information Technology
<i>GPS</i>	Global Positioning System
<i>SIG</i>	Système d'Information Géographique
<i>FMS</i>	Farm Management Software
<i>ANN</i>	Réseau Neuronal Artificiel
<i>CNN</i>	Réseau de Neurones Convolutifs
<i>RNN</i>	Réseau de Neurones Récurrents
<i>kNN</i>	K-nearest neighbors
<i>TFRA</i>	Union européenne-Union africaine sur l'Afrique rurale
<i>GFFA</i>	Forum mondial pour l'alimentation et l'agriculture
<i>LSTM</i>	Long Short-Term Memory
<i>SGA</i>	Systèmes de Gestion Agricole
<i>IoT</i>	Internet of Things
<i>ML</i>	Machine Learning
<i>DL</i>	Deep Learning
<i>IA</i>	Intelligence Artificielle
<i>EP</i>	Élevage de Précision
<i>PLF</i>	Precision Livestock Farming
<i>JDBC</i>	Java DataBase Connectivity
<i>MLlib</i>	Machine Learning Library
<i>UAV</i>	Unmanned Aerial Vehicle
<i>NDVI</i>	Normalized Difference Vegetative Index
<i>NIR</i>	Near-Infrared
<i>PRIMA</i>	Partenariat pour la Recherche et l'Innovation Méditerranéenne
<i>NT</i>	Nouvelles Technologies
<i>HDFS</i>	Hadoop Distributed File System
<i>BDA</i>	Big data Analytique
<i>DSS</i>	Decision Support Systems
<i>LBP</i>	Local Binary Pat- tern
<i>HOG</i>	Histogram of Oriented Gradients
<i>MS COCO</i>	Microsoft Common Objects in Context
<i>RF</i>	Random Forest
<i>FPGA</i>	Field-Programmable Gate Array

<i>RVB</i>	Rouge, Vert, Bleu
<i>DBN</i>	Deep Belief Network
<i>MCA</i>	Macroscopic Cellular Automata
<i>GLM</i>	Modèle Linéaire généralisé
<i>GBM</i>	Gradient Boosting Machine
<i>HSV</i>	Hue Saturation Value
<i>mPA</i>	Mean Average Precision
<i>MAE</i>	Mean Absolute Error
<i>RMSE</i>	Root Mean Square Error
<i>FPN</i>	Feature Pyramid Networks
<i>FPS</i>	Frame Per Second
<i>MIMD</i>	Multiple Instructions on Multiple Data
<i>SIMD</i>	Single Instructions on Multiple Data
<i>CUDA</i>	Compute Unified Device Architecture
<i>ACP</i>	L'analyse en composantes principales
<i>ReLU</i>	Rectified Linear Unit
<i>ELU</i>	Exponential Linear Unit
<i>CPU</i>	Central Processing Unit
<i>GPU</i>	Graphics Processing Unit
<i>SVM</i>	Support Vector Machine
<i>YOLO</i>	You Only Look Once
<i>VGG</i>	Visual Geometry Group
<i>ResNet</i>	Residual Neural Network

Introduction générale

Selon l'Organisation des Nations Unies pour l'alimentation et l'agriculture (FAO), la population mondiale devrait atteindre 9,2 milliards d'habitants en 2050. Ainsi, les agriculteurs devront produire 70% de plus pour satisfaire cette demande qui s'accroît au fil des années. En outre, de nombreux pays connaissent un énorme préjudice pour l'environnement en raison de l'utilisation accrue d'herbicides pour réduire l'effet des mauvaises herbes dans les champs agricoles. En égard à ces contraintes, les producteurs sont appelés à utiliser des modèles agricoles de nouvelle génération au lieu des méthodes traditionnelles et classiques afin de booster la productivité et préserver la rentabilité de l'agriculture. De surcroît, pendant les deux dernières décennies, avec l'évolution des nouvelles technologies de l'information et de la communication (NTIC), tous les secteurs basculent vers un nouveau mode d'agriculture basé essentiellement sur la digitalisation de ses processus et filières, ne considérant plus le digital comme un centre de coût, mais plutôt un centre de profit en vue d'un meilleur retour sur investissement. Dans cette optique, l'intérêt principal de la digitalisation de l'agriculture est d'améliorer la productivité pour faire face aux nombreux défis qui menacent la sécurité alimentaire, à savoir : la démographie, la pollution, l'épuisement des ressources naturelles, les changements climatiques.

En effet, plusieurs concepts ont émergé pour exprimer différentes formes de digitalisation de l'agriculture. Celles-ci incluent : L'agriculture digitale, l'agriculture de précision, smart agriculture et l'agriculture 4.0. Ce sont toutes des formes de modernisation et de digitalisation de l'agriculture en vue d'une meilleure performance. D'autres chercheurs voient l'agriculture 4.0 comme la dernière révolution agricole qui englobe toutes ces formes d'agriculture basée sur les dernières technologies du digital pour améliorer le rendement et la productivité agricole. Toutefois, le recours aux nouvelles tendances informatiques (Big data Analytics, AI, Cloud, IoT, etc.) est susceptible de garantir plus d'optimisation, de rationalisation et de performances. Mieux encore, les technologies avancées du digital telles que le « Cloud Computing », les Blockchains et l'internet des objets « IoT » se sont combinés avec l'intelligence artificielle « IA », les technologies robotiques et l'analyse des données massives « Big data Analytics » en vue d'enclencher la révolution « Agriculture 4.0 ».

En particulier, les mauvaises herbes génèrent une concurrence féroce et accrue à l'encontre des bonnes cultures dans un champ agricole. Leur utilisation excessive des ressources allouées,

toutes catégories confondues, influencent considérablement la productivité et rendement agricoles. Pour y remédier, la gestion des mauvaises herbes spécifiques aux sites agricoles demeure l'une des pratiques clés d'une agriculture de précision. C'est également l'une des mesures efficaces pour réduire l'utilisation des pesticides, économiser les coûts, améliorer le contrôle des mauvaises herbes et éviter une pollution inutile de l'environnement. Traditionnellement, les mauvaises herbes sont contrôlées mécaniquement, thermiquement et même chimiquement en appliquant des herbicides dans le champ, mais avec un coût élevé et un rendement non optimal. En pratique, le désherbage chimique est le traitement préféré de la plupart des agriculteurs conventionnels. Cependant, une pression croissante s'exerce sur les exploitations agricoles pour qu'elles réduisent l'utilisation des herbicides, en raison de leur effet indésirable sur l'environnement. Cela pousse l'agriculteur à inspecter ses champs avant de les pulvériser et à n'utiliser que des dosages adaptés aux besoins spécifiques de son exploitation. C'est un processus très fastidieux et non rentable, d'où la nécessité d'un processus rénové pour détecter efficacement les mauvaises herbes et réduire, ainsi, la charge des manœuvres agricoles. Cela étant, notre problématique ne se limite pas uniquement à l'utilisation des algorithmes de deep learning dans le domaine agricole, mais exige aussi une aide à la compréhension et à la construction des modèles innovant dans des problèmes typiques de l'agriculture en particulier, le processus des mauvaises herbes. Dans ce contexte, les questions qui viennent instinctivement à l'esprit se présentent comme suit :

- Comment le digital peut transformer l'agriculture et quelles sont les approches pouvant contribuer à son amélioration?
- Comment le deep learning peut être exploité au profit de la digitalisation de l'agriculture?
- Comment pouvons-nous créer, améliorer et appliquer des modèles de Deep Analytics à la détection des mauvaises herbes ?

Comme contribution académique à cette vision, ce travail de thèse met particulièrement la lumière sur l'utilisation du deep learning « DL » comme étant l'une des techniques de l'intelligence artificielle les plus répandues en termes de classification des objets et d'analyse prédictive des données. Toutefois, les algorithmes du DL ne sont pas assez exploités dans le secteur agricole et agro-industriel. Cela constituait pour nous une issue profitable pour démontrer la valeur ajoutée de la transformation digitale dans le domaine agricole, en zoomant, particulièrement, sur la détection des mauvaises herbes via des techniques de DL. En plus du rôle que joue la découverte en temps réel de l'emplacement des mauvaises herbes dans la facilitation du processus de

pulvérisation localisée, il existe une autre raison importante pour découvrir les espèces des mauvaises herbes et déterminer leur type. Pour comprendre l'importance de ce processus, nous devons comprendre la méthode de traitement des mauvaises herbes : Il existe deux types de plantes, qu'elles soient des cultures ou des mauvaises herbes, les premiers types sont des monocotylédones et les deuxièmes sont des dicotylédones. Les Monocotylédones sont des plantes dont la plantule issue de la germination d'une graine, ne présente tout d'abord qu'une seule feuille (le blé, l'alpiste paradoxal, etc.), les dicotylédones sont des plantes qui présentent deux feuilles primaires parallèles au cours de leurs premiers stades de croissance (les betteraves, le liseron, etc.). Les mauvaises herbes ont des herbicides selon chaque type. Si les mauvaises herbes sont monocotylédones, elles peuvent être traitées avec des herbicides spécifiques aux monocotylédones et si ce sont des mauvaises herbes dicotylédones, elles peuvent être traitées avec des herbicides spécifiques aux dicotylédones. Le problème ici est que parfois les cultures et les mauvaises herbes sont du même type (les cultures sont aussi monocotylédones que les mauvaises herbes, ou les cultures sont dicotylédones aussi que les mauvaises herbes). Ici, on ne peut pas utiliser cette méthode de deux types, car cela causera des dommages aux cultures. La solution étant d'utiliser des herbicides sélectifs spécifiques à chaque type, cela nécessite une détection précoce des espèces de mauvaises herbes. Nous avons donc proposé de créer des modèles d'apprentissage en profondeur qui détectent les espèces de mauvaises herbes et proposent les herbicides sélectifs. En résumé, les modèles d'apprentissage en profondeur peuvent déterminer l'emplacement des mauvaises herbes en temps réel et effectuer une pulvérisation localisée, ils aident également à identifier les types de mauvaises herbes et à suggérer un herbicide particulier à celle-ci, ce qui rend le processus de traitement et de pulvérisation plus efficaces, économique et ami de l'environnement, optimisant le temps et l'effort.

L'objectif principal de cette recherche est de contribuer à la concrétisation de la digitalisation du processus de détection des mauvaises herbes par le biais des techniques du deep learning. Cela repose sur la construction de modèles typiques d'apprentissage en profondeur pour la détection des mauvaises herbes dans les champs de céréales et dans les champs de betteraves sucrières avant que leurs symptômes ne soient visibles à l'œil nu. Dans ce travail, nous apportons une méthodologie expérimentale susceptible de démontrer les capacités du deep learning dans la détection des adventices et de comprendre son effet crucial pour une agriculture de précision. Cela se manifeste par la proposition de méthodes de renforcement des résultats des modèles de DL favorisant la détection précoce des mauvaises herbes en vue d'enrichir le réservoir de la communauté scientifique quant à l'utilisation de l'apprentissage en profondeur dans la culture des champs.

Cette contribution est axée principalement sur la détection des critères qui influencent les résultats de l'entraînement des modèles de deep learning, l'amélioration des algorithmes de deep learning, ainsi que sur la combinaison des algorithmes ResNeXt et Support Vector Machine (SVM) pour obtenir un modèle hybride (ResNeXt-SVM) qui n'a jamais été utilisé. Ces modèles sont testés sur des données locales et se sont révélés efficaces pour la détection et la classification des mauvaises herbes, offrant une cartographie plus claire des plantes adventices avant qu'elles ne soient observées visuellement. Ces techniques peuvent être utilisées également dans divers domaines liés à l'agriculture, tels que la découverte des maladies des plantes, la chasse aux criquets, la pulvérisation ciblée, la classification des cultures, la catégorisation des feuilles de plantation, la reconnaissance automatique de fleurs, etc.

Le manuscrit relatif à ce travail est structuré comme suit : Après l'introduction générale, nous apportons, dans le premier chapitre, la base théorique de l'agriculture digitale ainsi qu'une revue de littérature en la matière. Dans le deuxième chapitre, nous nous intéressons aux approches de l'intelligence artificielle pour l'agriculture avec des études et des benchmarks de différentes techniques, outils et algorithmes de machine learning et deep learning. Dans le troisième chapitre, nous mettons en exergue l'application du deep learning dans le domaine agricole et plus précisément pour la détection des mauvaises herbes dans les parcelles agricoles. Pour enrichir cette partie, nous présentons les résultats d'une expérience que nous avons menée, où nous avons utilisé des algorithmes open source de détection d'objets. Le quatrième chapitre est réservé à une étude pratique déployant des modèles spécifiques de DL pour la détection des plantes adventices. Nous y proposons particulièrement l'entraînement des modèles avec différentes architectures sur différentes données. Dans chaque cas, nous avons suggéré des moyens d'améliorer et de booster les résultats en utilisant différentes techniques. Dans le dernier chapitre, nous appréhendons davantage dans les voies possibles pour améliorer la performance d'un modèle d'apprentissage profond. Cette étude est à l'origine de la création d'un modèle hybride basé sur une combinaison des algorithmes ResNeXt et la Machine à Vecteurs de Support (SVM) pour la détection des mauvaises herbes. Nous clôturons ensuite, ce rapport, par une conclusion générale et futures perspectives de développement dans ce domaine.

CHAPITRE

I

**REVUE DE LITTÉRATURE:
AGRICULTURE DIGITALE ET DE PRÉCISION**

1. Introduction

La transformation agricole est une priorité dans l'agenda politique des gouvernements dans leur quête pour relever les défis de l'insécurité alimentaire et nutritionnelle, du changement climatique, du chômage des jeunes et de la croissance économique mondiale. Avec les bonnes politiques, l'innovation et l'investissement, l'agriculture du continent pourrait être transformée en une centrale électrique non seulement pour nourrir une population croissante, mais aussi pour créer des emplois décents pour des millions de jeunes [1].

La technologie, comme nous l'avons vu dans d'autres secteurs, est essentielle pour influencer sur le changement et stimuler le développement [2]. Il rapproche les pays, réduit les barrières commerciales et offre une fenêtre d'opportunité aux jeunes entrepreneurs « natifs du numérique » à la pointe de l'innovation appliquée à différents secteurs économiques. Dans l'agriculture, la digitalisation pourrait changer la donne en augmentant la productivité, la rentabilité et la résilience au changement climatique [3].

Comme prévu, ces dernières années, le secteur des technologies agricoles a évolué comme d'autres secteurs et a progressé pour devenir une entreprise à forte intensité de connaissances. Avec ce changement, les systèmes de production traditionnels se sont transformés en systèmes modernes, productifs et innovants [4]. La numérisation de l'agriculture a connu une croissance significative au cours des dix dernières années. En 2019, le rapport du groupe de travail Union européenne-Union africaine sur l'Afrique rurale (TFRA) et le communiqué du Forum mondial pour l'alimentation et l'agriculture (GFFA) ont souligné le pouvoir de la numérisation dans la transformation de l'agriculture [5], ce concept dans les temps récents et dans un futur proche signifie : l'agriculture avec des économies d'eau, l'agriculture intelligente, l'agriculture de haute qualité, de haute efficacité et non polluante. L'agriculture numérique est l'approche la plus efficace et nécessaire pour réaliser toutes ces transformations [6].

Les techniques de la transmission à l'agriculture digitale sont nombreuses à savoir, l'intelligence artificielle, Blockchains, Big data Analytics, IoT (Internet des objets), Impression 3D. Cette transformation numérique touche un ensemble de domaines agricoles à savoir, le service d'élevage, le service d'irrigation, les cultures [7].

L'objectif de ce chapitre est de se préparer pour développer cette idée de la transformation digitale en agriculture et comprendre par la suite les voies d'amélioration possible, nous passons en revue de littérature sur divers défis agricoles ainsi les aspects de la digitalisation de l'agriculture, puis résumons plusieurs nouvelles approches et outils utilisés à cet effet, afin d'identifier les problèmes

et les défis rencontrés dans ce processus de transition vers l'agriculture 4.0. Ensuite, nous présenterons les différents domaines agricoles concernés par cette modernisation et terminons par une conclusion. Nous avons exploité les résultats des articles que nous avons publiés dans des revues indexées Scopus, le premier article [8] discute des technologies d'analyse de données, l'autre [9] parle de la prise de décision dans plusieurs domaines, ces idées peuvent être utilisées dans le domaine agricole. Le dernier présente l'agriculture digitale et les techniques qui y sont utilisées [10].

2. Défis agricoles

Un certain nombre de tendances mondiales influencent la sécurité alimentaire, la pauvreté et la durabilité globale des systèmes alimentaires et agricoles.

Les quatre principales évolutions qui mettent l'agriculture sous pression pour répondre aux exigences de l'avenir sont les suivantes : la démographie, la raréfaction des ressources naturelles, la pollution, le changement climatique et le gaspillage alimentaire.

2.1 Augmentation de la démographie

Au cours des prochaines décennies, la population mondiale devrait augmenter de 33%, pour atteindre près de 10 milliards d'habitants en 2050, contre 7,6 milliards (en octobre 2017). En 2100, la population mondiale devrait atteindre 11,2 milliards. Ce chiffre peut sous-estimer les taux de fécondité réels - selon d'autres scénarios, la population pourrait atteindre 16,5 milliards. La croissance démographique stimulera la demande alimentaire, même dans un scénario de croissance économique modeste, d'environ 50% par rapport à la production agricole de 2013 [11].

L'urbanisation mondiale entre aujourd'hui et 2050 pourrait entraîner un ajout net de 2,4 milliards de personnes dans les villes. L'urbanisation stimule l'amélioration des infrastructures. Elle tend également à augmenter les revenus, ce qui accroît la demande d'aliments transformés et d'aliments d'origine animale dans le cadre d'une transition alimentaire plus large [12].

En d'autres termes, l'augmentation de la population entraîne une hausse de la demande, qui se traduit à son tour par une augmentation de la production. Selon l'Organisation des Nations Unies pour l'alimentation et l'agriculture (FAO), les agriculteurs devront produire 70% de nourriture en plus d'ici 2050 comme le montre la figure 1-1. Cette nourriture devra être adaptée aux besoins d'une population urbaine croissante.



Figure 1- 1: Une forte augmentation de la démographie stimulera la demande de produits alimentaires

Les terres agricoles mondiales sont de plus en plus impropres à la production : sur la base de certains paramètres, 25% de toutes les terres agricoles sont déjà considérées comme fortement dégradées, tandis que 44% sont modérément ou légèrement dégradées. Les ressources en eau sont très fortement sollicitées, plus de 40% de la population rurale plus mondiale vit dans des zones où l'eau est rare. La terre est reconnue depuis longtemps comme une ressource limitée [13].

L'agriculture classique est une cause primaire - et une victime indirecte - de la dégradation des terres agricoles, les différents aspects agricoles contribuant à ce processus de diverses manières. L'érosion des sols est causée par la coupe excessive de la végétation (défrichage pour la création de terres agricoles), ainsi que par des périodes de jachère mal orchestrées, la rotation des cultures et le surpâturage du bétail. L'utilisation déséquilibrée d'engrais pour rétablir le rendement entraîne un déséquilibre des nutriments.

Les mauvaises herbes sont contrôlées chimiquement en appliquant des herbicides sur le champ. L'efficacité des herbicides sur les mauvaises herbes les plus pernicieuses peut être limitée parce que les gouttelettes de pulvérisation ne sont pas bien retenues ou parce que la pénétration et/ou la translocation sont restreintes. En conséquence, le produit chimique pollue l'environnement est dangereux pour la santé humaine [14].

Tous ces problèmes sont le résultat d'un manque de prévoyance et de planification. Le manque de terres et la pauvreté entraînent des pratiques de gestion des terres non durables, qui sont les causes directes de la dégradation mentionnée ci-dessus.

2.2 Changement climatique

Le changement climatique modifie rapidement l'environnement. Le degré d'émissions de gaz à effet de serre d'origine humaine a atteint le plus haut niveau de l'histoire, selon un rapport de 2014 du Groupe d'experts intergouvernemental sur l'évolution du climat [15].

Réduction de la productivité de l'agriculture (figure 1-2) : le changement climatique a pour effet secondaire d'accroître la variabilité des précipitations et d'augmenter la fréquence des sécheresses et des inondations, ce qui tend à réduire le rendement des cultures. Des études ont documenté que

les rendements des cultures diminuent considérablement lorsque les températures diurnes dépassent un certain niveau spécifique à la culture [16].

Le changement climatique affectera tous les aspects de la production alimentaire : l'augmentation de la variabilité des précipitations et la multiplication des sécheresses et des inondations sont susceptibles de réduire les rendements.

En l'absence d'efforts d'adaptation au changement climatique, l'insécurité alimentaire augmentera considérablement : l'impact du changement climatique sur la sécurité alimentaire mondiale ne concernera pas seulement l'approvisionnement en nourriture, mais aussi la qualité, l'accès et l'utilisation des aliments [16].




Figure 1- 2: Le changement climatique réduit la productivité de l'agriculture

3. Recherches existantes

Nous avons mené une revue de littérature englobante autour des différentes technologies avancées utilisées dans le domaine agricole et agro-alimentaire dans le dessein de relever des pistes d'amélioration. Ainsi, à l'image de ce graphique (figure 1-3), que nous avons retiré de Scopus, il s'est avéré que les recherches sur la digitalisation de l'agriculture à l'échelle internationale sont encore peu nombreuses, mais le nombre monte progressivement ces dernières années pour avoisiner un peu plus de 500 recherches en 2021. Sur le plan national, ce nombre est très modeste, que ce soit dans l'utilisation de certaines technologies ou dans la digitalisation de l'agriculture d'une manière générale, bien qu'il y ait eu l'apparition de certains articles publiés dans ce domaine à partir de 2019.

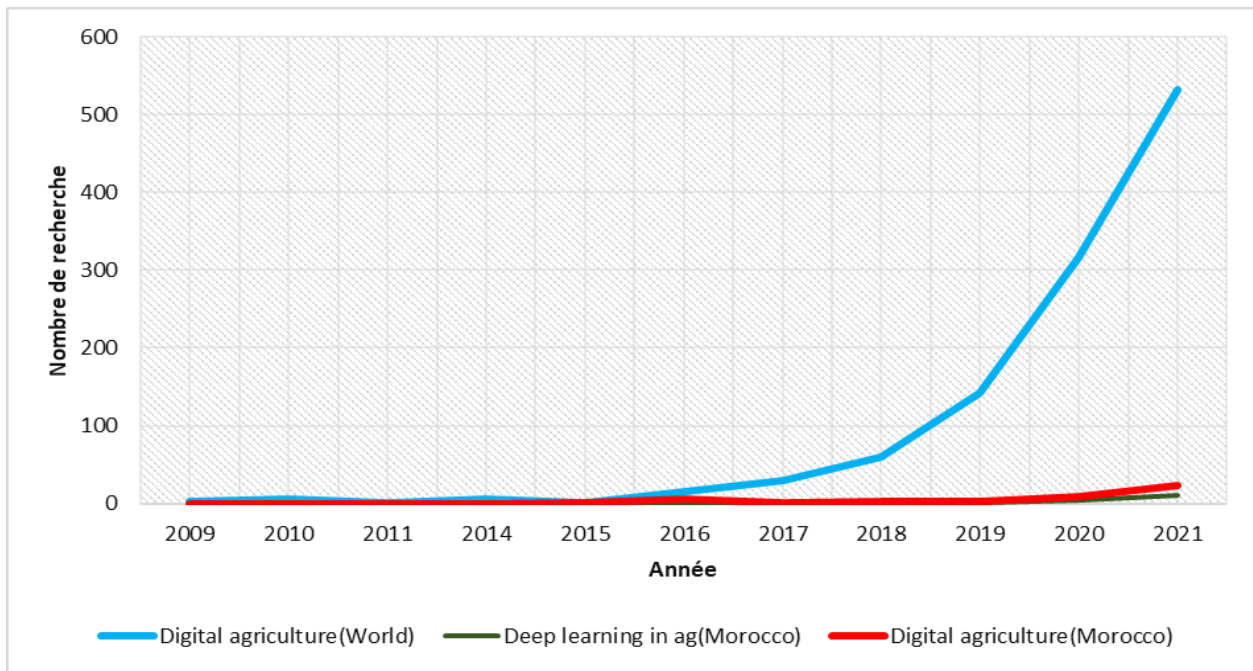


Figure 1- 3: Utilisation des technologies avancées du digital dans l’agriculture

Ayant analysé un bon échantillon de ces articles, il nous a été donné de constater que la communauté scientifique propose diverses techniques, modèles et approches basés sur le digital en vue de concrétiser cette notion d’agriculture digitale à travers plusieurs processus et filières de l’agriculture. Les sections suivantes présenteront ces approches ainsi que les différentes formes de modernisation de l’agriculture et les technologies utilisées dans cette transformation qui ont été abordées dans ces articles récents.

4. Agriculture 4.0 et l’agriculture de précision

L’agriculture 4.0 devra prendre en compte à la fois la demande et la chaîne de valeur/l’offre de l’équation de la pénurie alimentaire, en utilisant la technologie non pour le plaisir d’innover, mais pour améliorer et répondre aux les besoins réels des consommateurs et réorganiser la chaîne de valeur. Les fermes et les exploitations agricoles modernes fonctionneront différemment, principalement en raison des progrès de la technologie et l’explosion des données et l’essor du Big data, notamment les capteurs, les dispositifs, les machines, les technologies de l’information et l’intelligence artificielle. L’agriculture du futur utilisera des technologies sophistiquées telles que les robots, les capteurs de température et d’humidité, les images aériennes, la technologie GPS et le deep learning, pour n’en citer que quelques-unes. Ces avancées permettront à l’agriculture d’être plus rentables, plus efficaces, plus sûres, plus écologiques et plus respectueuses de l’environnement.

4.1 Agriculture basée sur les technologies avancées du Digital

Les approches existantes dans le secteur agricole tentent de tirer parti des technologies intelligentes innovantes qui apportent des solutions technologiques à tous les niveaux de la production agricole. Investissement, manœuvres, production puis commercialisation (figure 1-4), permettant aussi de développer une structure de gestion agricole auto-optimisée de bout en bout dans le contexte de l'agriculture 4.0 qui peut être facilement organisée et utilisée par tous les acteurs concernés et parties prenantes. Certaines technologies clés qui sont particulièrement importantes pour l'agriculture 4.0, ainsi que leurs capacités et leurs effets au profit d'une gestion agricole durable sont présentés dans les sous-sections suivantes.

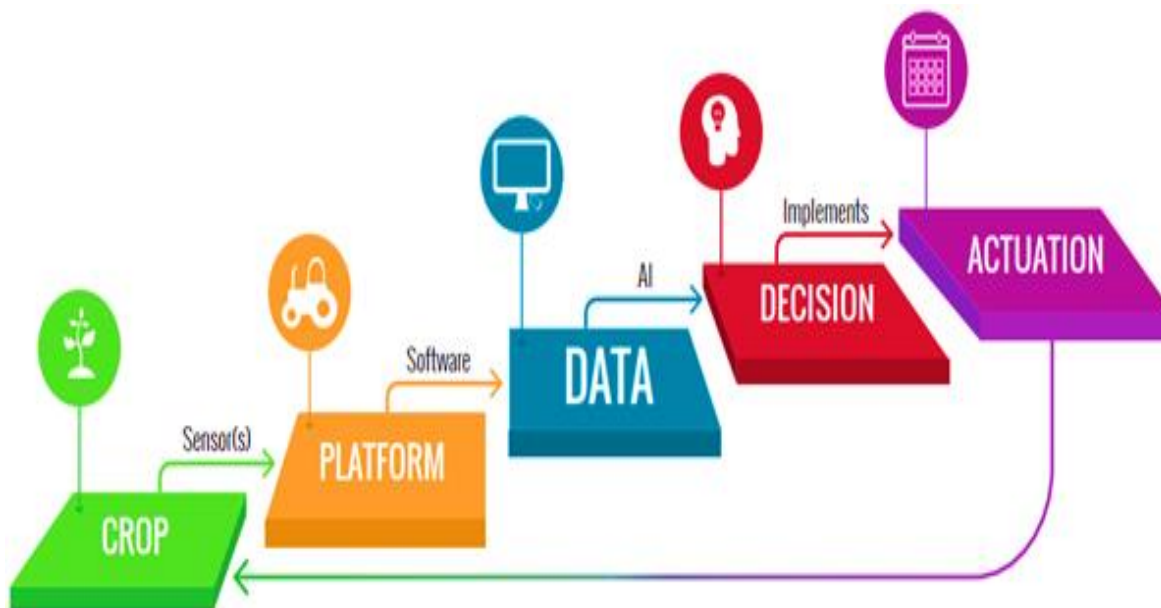


Figure 1- 4: Cycle de gestion basé sur l'information pour l'agriculture 4.0

4.1.2 Cloud Computing en agriculture

Le Cloud Computing, souvent appelé simplement "le Cloud", est une technologie qui a été lancée au début ou au milieu des années 2000 [17] afin de fournir des ressources informatiques matérielles, logicielles et de stockage livré sous forme de service sur un réseau privé ou public tel qu'Internet. En particulier, le Cloud Computing intègre un système parfait, capable de distribuer des services informatiques à la demande aux utilisateurs en combinant une puissance de calcul élevée, des technologies de stockage et de réseau en ce qui concerne l'équilibre de la charge et la réutilisation [18]. La figure 1-5 montre le rôle du Cloud par rapport aux différentes opérations liées à la gestion de l'agriculture et sa relation aux différents services.

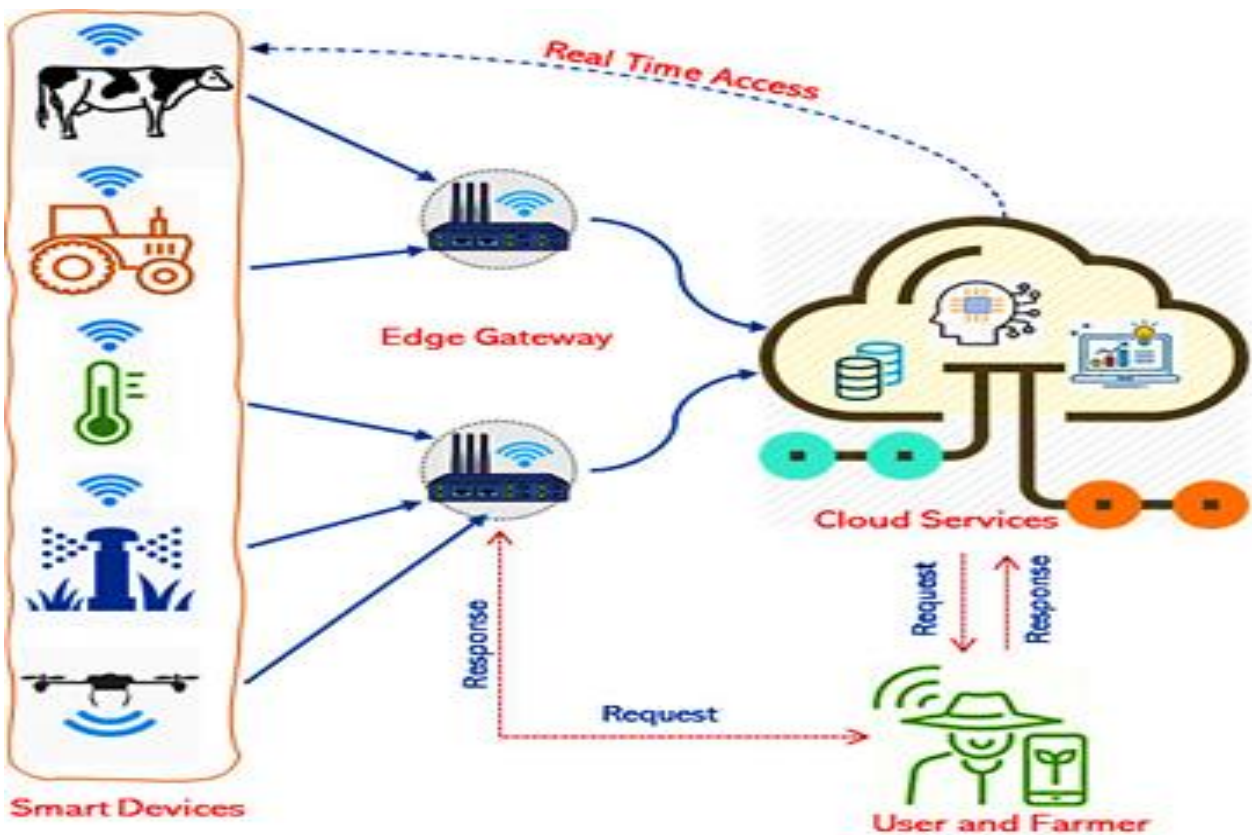


Figure 1- 5: Utilisation du cloud dans l'agriculture intelligente

Si l'on tient compte du fait que les environnements agricoles ont tendance à générer des quantités volumineuses de données sensorielles hétérogènes qui correspondent à d'énormes espaces de stockage, alors que le développement d'infrastructures intelligentes sophistiquées augmente constamment la demande de services intelligents plus complexes [19], la réalisation de ces opérations sur des serveurs locaux pourrait entraîner un manque d'évolutivité et l'inefficacité des systèmes de gestion agricole (SGA).

Étant donné que le Cloud Computing est une technologie de l'information et de la communication (TIC). Il est considéré comme délibéré de transposer les opérations de traitement et de stockage des données des infrastructures locales vers des environnements distribués, afin de faciliter la gestion de ces quantités extrêmement importantes de données agricoles et, par conséquent, d'améliorer le temps de traitement et de génération de l'information, ainsi que d'étendre la capacité de fournir des services complexes et spécialisés pour les SGA [20].

4.1.3 Agricultural Internet of Things (AIoT)

L'internet des objets (IoT) peut être sémantiquement défini comme un réseau mondial d'objets adressables de manière unique et qui sont interconnectés sur la base de protocoles de communication standard, comme l'internet [21]. Par conséquent, l'internet sert d'infrastructure de stockage et de communication incorporant des représentations d'objets virtuels qui intègrent des informations pertinentes aux objets physiques. Dans ce contexte, les objets virtuels servent de centres d'information centralisés sur les objets, mettant à jour et combinant en permanence des données provenant d'un large éventail de sources diverses, de manière à contrôler tout processus requis à distance via Internet.

Selon les directives de l'industrie 4.0, les objets physiques et virtuels sont interconnectés, comme le montre la figure 1-6, ils sont contrôlés par des réseaux intelligents établis tout au long de la chaîne de valeur [22][23]. Sur la base de ce concept, la structure des objets virtuels est étroitement liée au concept d'IoT, qui, dans le secteur agricole comme dans le secteur industriel, peut s'exprimer par certaines caractéristiques spécifiques, telles que l'hétérogénéité, due à une variété de dispositifs, l'interconnectivité, la haute évolutivité, les services liés aux objets et, enfin, les changements dynamiques puisque l'état des dispositifs peut changer dynamiquement à tout moment [24].




Figure 1- 6: Utilisation IoT agricole

L'IoT agricole (AIoT) indique un cadre prometteur selon les directives de l'agriculture 4.0, grâce auquel diverses données liées aux exploitations agricoles peuvent être acquises, traitées, gérées et diffusées en tant que mécanisme par lequel une série diverse de systèmes et de services peuvent être intégrés de manière transparente dans les SGA [25]. De tels systèmes seront en mesure de :

- Traiter avec succès les divers flux de données en temps réel.
- Traiter des données diverses, incomplètes et, dans certains cas, contradictoires.
- Acquérir, corrélérer et fusionner des données en temps réel.
- Affecter dynamiquement le comportement du réseau pour modifier les règles d'acquisition, d'acheminement ou d'enregistrement des données.

Par conséquent, l'AIoT est considéré comme une technologie indispensable pour les fermes intelligentes, tandis que son développement en relation avec l'approche de l'internet du futur offre une base pour une nouvelle génération de systèmes d'information de gestion agricole, permettant à des fermes intelligentes entières de devenir des nœuds actifs dans les chaînes de valeur agricoles.

4.1.4 Big Data Analytics en agriculture

L'élan récent de la technologie IoT, qui interconnecte sans fil toutes sortes d'objets et de dispositifs, à toutes les étapes du cycle de gestion cyber-physique, produit de grandes quantités de données accessibles en temps réel sur les processus agricoles ainsi que sur l'ensemble de la chaîne d'approvisionnement. À cet égard, les opérations et les transactions sont des sources très importantes de données médiatisées par les processus. En outre, les dispositifs sensoriels et les robots produisent des données non traditionnelles telles que des images, des vidéos et d'autres types de données générées par des machines, tandis que les médias sociaux constituent également une source importante de données d'origine humaine. Par conséquent, à ces grandes quantités de données hétérogènes, l'accès à des informations explicites et à des capacités de prise de décision est fourni à un niveau qui n'était pas possible auparavant. Le facteur clé de la réussite pour créer de la valeur à partir de ces données est le Big data et la technologie analytique.

Les Big data modifient le champ d'action et l'organisation de l'agriculture, car elles sont utilisées pour fournir des informations prédictives sur les opérations agricoles, pour prendre des décisions opérationnelles en temps réel et pour redéfinir les processus [26]. Des questions importantes, telles que l'amélioration de l'efficacité, la sécurité et la sûreté alimentaires, le changement climatique et la durabilité, doivent être abordées par les applications du Big data [27][28].

4.1.5 Intelligence Artificielle appliquée à l'agriculture

Afin de permettre une gestion efficace des risques, de réduire les coûts de prédiction sur la prise de décision et, par la suite, d'améliorer la précision de l'agriculture et d'augmenter la productivité, les techniques d'IA et de ML fournissent des applications et des systèmes logiciels

intelligents capables d'effectuer des opérations de travail de la connaissance impliquant des jugements subtils et des commandes non structurées [29].

Les environnements agricoles étant caractérisés par d'énormes quantités d'informations, plusieurs niveaux d'abstraction des données et diverses techniques de sélection des caractéristiques, telles que la classification et le regroupement, sont nécessaires pour obtenir la valeur exacte du contenu de données hétérogènes. Les techniques de classification par fusion de données, en particulier, peuvent être largement utilisées dans les environnements multisensoriels pour fusionner et agréger les données de plusieurs capteurs hétérogènes distribués (comme ceux déployés dans les champs agricoles), afin de réduire la probabilité d'erreur de détection et d'améliorer la fiabilité [30]. À cette fin, les FMS peuvent utiliser diverses méthodes basées sur l'IA, telles que les réseaux neuronaux artificiels (ANN), les algorithmes deep learning tels que Convolutional Neural Networks (CNN) et Recurrent Neural Network (RNN), tandis que dans certains cas, l'apprentissage non supervisé peut également être appliqué. En outre, le clustering, en tant que technique d'analyse exploratoire des données, est largement utilisé pour identifier des sous-groupes (clusters) dans les données en fonction de la similarité ou de la diversité des points de données [31].

En outre, en appliquant des techniques de ML, les systèmes de gestion agricole (SGA) peuvent évoluer vers de véritables systèmes d'IA d'où on parle d'une agriculture de précision, fournissant des informations et des suggestions plus sophistiquées pour toutes les décisions et actions ultérieures, visant finalement à améliorer la production agricole. En ce sens, on s'attend à ce que l'incorporation de modèles ML dans les SGAs se développe encore davantage dans un avenir proche grâce à l'intégration de l'enregistrement automatisé des données, de l'analyse des données, de la mise en œuvre de ML et de la prise de décision ou de l'aide à la décision, fournissant ainsi des outils pratiques conformes aux directives de l'Agriculture 4.0 visant à augmenter la production et la qualité des produits agricoles en termes de durabilité.

4.2 Benchmark des technologies existantes dans le domaine agricole

De tout ce qui précède, il ne fait aucun doute que ces nouvelles technologies transforment la façon dont le secteur agricole s'organise et prend des décisions. Afin de donner un aperçu général de la façon dont la nouvelle technologie numérique transforme les chaînes d'approvisionnement agroalimentaires, les tableaux (tableau 1-1, tableau 1-2, tableau 1-3 et tableau 1-4) intègrent et classent également les principaux impacts positifs des technologies les plus pertinentes. Que les

défis à relever selon les études récentes dans les domaines portés par différents auteurs. Ces points forts et limites répartissent entre ce qui est fonctionnel, technologique, social, économique et environnemental.

Tableau 1- 1. Intelligence artificielle : Points forts et limites

Références	[32,33, 34, 35, 36, 37, 38]
Points forts	<p>❖ Fonctionnels :</p> <p>Les algorithmes d’IA offrent la possibilité pour :</p> <ul style="list-style-type: none"> ▪ Classification : pour prédire les catégories de données d’entrée, par ex. classification des cultures, prédiction des attributs météorologiques, ensoleillés, venteux, pluvieux, etc. ▪ Régression : pour prédire une valeur numérique, par exemple prix des actions. ▪ Regroupement : pour organiser des éléments similaires en groupes. ▪ Analyse d’association : pour trouver des liens intéressants entre des ensembles de variables. ▪ Arbre de décision : pour prédire les informations de modélisation des variables objectives en apprenant des règles de décision simples déduites des caractéristiques des données. ▪ Analyse graphique : pour utiliser des structures graphiques pour trouver des liens utiles entre les entités. <p>Les capacités ci-dessus ont été appliquées aux :</p> <ul style="list-style-type: none"> ▪ Gestion des cultures (prévision du rendement, détection des maladies, détection des mauvaises herbes, insectes nuisibles, stress biotique dans la culture, qualité de la culture, reconnaissance des espèces, prédiction de l’humidité du sol). ▪ Gestion de l’eau (systèmes d’irrigation intelligents). ▪ Prévision météo. ▪ Gestion des sols. ▪ Surveillance plus rapide et plus précise que les autres systèmes de surveillance. <p>❖ Économiques :</p> <ul style="list-style-type: none"> ▪ Réduit les coûts de la main-d’œuvre. ▪ Réduit l’effort et le temps d’intervention. ▪ Aide à la prise de décision en temps réel et à faible coût. ▪ Améliore l’utilisation de la plupart des données disponibles. ▪ ML et DL fournissant aux entreprises une analyse intelligente des mégadonnées structurées et non structurées.

	<ul style="list-style-type: none"> ❖ Sociaux : <ul style="list-style-type: none"> ▪ Réduit le nombre d’erreurs humaines. ▪ Examine les transactions ignorées par les experts humains. ▪ S’occupe des opérations précises ce qui permet à l’expert humain de se concentrer sur d’autres tâches. ❖ Technologiques : <ul style="list-style-type: none"> ▪ L’avancement de l’intelligence artificielle avec la vision industrielle nous donne des technologies agricoles robustes, avancées, précises et peu coûteuses. ▪ Offre une grande puissance de filtre et de nettoyage des données mal structurées et mal présentées et mal organisées. ▪ Résout les problèmes liés au Big Data, vitesse, variété, volume, etc. ▪ Des machines intelligentes aux ordinateurs intelligents et aux programmes d’intelligence artificielle (IA). ▪ Contribue au développement des systèmes experts dans plusieurs domaines (détection des mauvaises herbes, irrigation intelligente, élevage de précision, etc.).
<p>Limites</p>	<ul style="list-style-type: none"> ❖ Sociales: <ul style="list-style-type: none"> ▪ Le remplacement de l’intervention humaine perçue comme une menace de la main-d’œuvre. ▪ Les systèmes à base de IA ne seront pas en mesure de donner les réponses créatives que celles des experts humains dans des circonstances inhabituelles. ❖ Technologiques : <ul style="list-style-type: none"> ▪ Doit toujours suivre le rythme du grand développement dans le domaine de la visualisation et de l’imagerie. ▪ Des problèmes de parallélisation pour les algorithmes d’IA qui sont conçus pour les environnements à machine unique. ▪ Dans bon nombre de ses applications, nécessite une connexion fil ou sans fil, ce qui rend cela difficile dans les zones rurales. ▪ Nécessite une flexibilité pour s’adapter aux environnements changeants. ▪ L’acquisition de connaissances reste le problème des algorithmes supervisés. ▪ L’implémentation exige un environnement matériel puissant. ▪ Nécessite son intégration avec d’autres technologies dans de nombreux problèmes agricoles.

Tableau 1- 2. Big data Analytique : Points forts et limites

Références	[39,40, 41, 42, 43, 44, 45, 46,47]
Points forts	<ul style="list-style-type: none"> ❖ Fonctionnels : <ul style="list-style-type: none"> ▪ Offre différents types d’analyse descriptive, prescriptive et prédictive des données pour en tirer des significations et prendre la bonne décision : identifier les risques agroalimentaires, prévision de la demande, du rendement, des prix, automatisation de la robotique, planification de la plantation et de la récolte des cultures. ❖ Économiques : <ul style="list-style-type: none"> ▪ Garantie une automatisation et à de meilleures décisions ce qui va améliorer l’efficacité opérationnelle. ▪ Offre des analyses prescriptives décrivant la planification des cultures basée sur des données agricoles historiques (rendements, conditions climatiques et météorologiques, détails des semences et engrais) pour augmenter la rentabilité de l’exploitation. ▪ Les cultures ainsi l’élevage sont mieux optimisés avec des méthodologies innovantes qui améliorent la production. ▪ Offre une livraison plus rapide et moins chère des produits. ▪ Garantie de bonnes décisions basées sur les données des champs et des équipements, ainsi fournit des alertes en temps réel. ▪ Les données de performances commerciales sont intégrées pour une meilleure prise de décision. ▪ Offre une forte compréhension des besoins des consommateurs et cible des marchés à plus forte valeur ajoutée. ▪ Facilite le développement de plateformes de commerce en ligne ou de coopératives virtuelles en ligne. ❖ Environnementaux : <ul style="list-style-type: none"> ▪ Meilleure gestion et utilisation des ressources (eau, pesticides, etc.). ▪ Contribue à la réduction des déchets. ❖ Sociaux : <ul style="list-style-type: none"> ▪ Transition vers une agriculture digitale fondée sur les connaissances au lieu d’une agriculture traditionnelle fondée sur les compétences. ▪ Services client plus optimisés. ▪ Minimise les risques. ❖ Technologiques : <p>Capacité liée essentiellement aux caractéristiques 5V des données:</p>

	<ul style="list-style-type: none"> ▪ Volume (ampleur des données). ▪ Vitesse (de génération et de livraison des données, qui peuvent être traitées par lots, en temps réel ou rationalisées). ▪ Variété (données de sources hétérogènes). ▪ Véracité (qualité des données et niveau de confiance). ▪ Valeur (détecter les données étant actionnables ayant une réelle valeur).
<p>Limites</p>	<ul style="list-style-type: none"> ❖ Organisationnelles : <ul style="list-style-type: none"> ▪ La décentralisation Big data avec ses inconvénients. ▪ Des défis au niveau de contrôle du Big data lorsque plusieurs acteurs sont impliqués. ▪ Nécessite plus de confidentialité, confiance et sécurité des données entre les acteurs. ❖ Sociales : <ul style="list-style-type: none"> ▪ Les entreprises agricoles et les individus ne se sont pas activement engagés dans ces innovations, en raison du coût. ▪ Implications éthiques du Big data dans l'alimentation et l'agriculture. ▪ L'analyse des mégadonnées nécessite des connaissances approfondies. ❖ Technologiques : <ul style="list-style-type: none"> ▪ Des problèmes de traitement liés aux 5V de données. ▪ Besoin de combinaison des trois niveaux d'analyse descriptive, prescriptive et prédictive (les performances de l'analyse prescriptive dépendraient fortement de celles de l'analyse descriptive et prédictive). ▪ Nécessite un développement des modèles BDA plus avancés et adaptatifs pour DSS. ▪ Manque de moyens pour aider à prendre la bonne décision et nécessite parfois l'intégration avec d'autres technologies. ▪ La position des agriculteurs dans les chaînes d'approvisionnement utilisant BDA n'est pas connue.

Tableau 1- 3. IoT: Points forts et limites

<p>Références</p>	<p>[48,49, 50, 51, 52, 53, 54]</p>
<p>Points forts</p>	<ul style="list-style-type: none"> ❖ Fonctionnels : <ul style="list-style-type: none"> ▪ Surveillance efficacement et en temps réel les détails de l'environnement (température, humidité, parasites, condition de culture, etc.). ▪ Signale les conditions urgentes qui nécessitent une intervention selon des critères

	<p>précis.</p> <ul style="list-style-type: none"> ▪ Fournit des solutions et des interventions sans intervention humaine. ▪ Assure le suivi et le traçage les objets. ▪ Efficace dans le domaine de culture et de l'élevage. <p>Économiques :</p> <ul style="list-style-type: none"> ▪ Minimise les coûts technologiques à tous les niveaux de la production agricole. Investissement, manœuvres, production puis commercialisation. ▪ Augmente la qualité et la quantité du rendement, surveille la santé/bien-être des animaux. <p>❖ Environnementaux :</p> <ul style="list-style-type: none"> ▪ Minimise l'impact des pesticides sur l'environnement grâce à la rationalisation de l'utilisation. ▪ Réduit le gaspillage de l'eau utilisée, ainsi les autres ressources naturelles. ▪ Réduit les déchets en analysant les données pour prendre la bonne décision au bon moment. <p>❖ Sociaux :</p> <ul style="list-style-type: none"> ▪ Augmente la satisfaction des clients à travers tous les services disponibles. ▪ Offre des programmes de certification offre une meilleure protection contre la fraude et la falsification. ▪ Minimise la main-d'œuvre requise. <p>❖ Commerciaux:</p> <ul style="list-style-type: none"> ▪ Crée de nouveaux canaux de commercialisation d'affaires (relation directe avec le client). ▪ Augmente les opportunités de coopération. <p>❖ Technologiques :</p> <ul style="list-style-type: none"> ▪ Connu par ses capteurs sans fil puissants à basse consommation. ▪ Offre une meilleure connectivité pair-à-pair.
<p>Limites</p>	<p>❖ Organisationnelles :</p> <ul style="list-style-type: none"> ▪ Les expériences réussies ne peuvent être généralisées, pas de solution unique, qu'elle soit technologique, ou réglementaire, qui s'adaptera aux besoins de tous (Hétérogénéité du secteur). ▪ Les coûts d'investissement dans ces technologies sont élevés et nécessitent une expertise coûteuse. ▪ Les différents modèles commerciaux et la confidentialité des affaires le rendent complexe.

	<ul style="list-style-type: none"> ❖ Sociales : <ul style="list-style-type: none"> ▪ Manque d'expertise technique requise, en particulier dans les pays du tiers monde. ▪ Problèmes d'intégration des usagers et de la société. ❖ Technologiques : <ul style="list-style-type: none"> ▪ L'automatisation nécessite de grands efforts dans la collection, le traitement et l'analyse des données (absence de services de traitement des données entrave considérablement l'IoT). ▪ Problèmes avec les données volumineuses, ainsi la complexité matérielle et logicielle. ▪ Manque d'interopérabilité des systèmes. ▪ Ces technologies nécessitent une connectivité (faible dans les zones rurales). ▪ Le contrôle et la propriété des données agricoles sont toujours controversés (Manque de gouvernance claire). ▪ Sécurité des données, confidentialité et anonymat. ▪ Une décentralisation qui constitue un obstacle à l'administration et à la gestion.
--	---

Tableau 1- 4. Blockchains : Points forts et limites

Références	[55,56, 57, 58, 59, 60, 61]
Points forts	<ul style="list-style-type: none"> ❖ Fonctionnels : <ul style="list-style-type: none"> ▪ Fournit une visibilité claire et en temps réel à tous les acteurs de la chaîne d'approvisionnement. ▪ Assure des liens immuables avec le processus produit, ces liens tracent l'origine et le cheminement des produits. ▪ Suivi des produits en temps réel pour gérer les produits défectueux ou endommagés. ▪ Améliore la vitesse de réponse, l'efficacité des processus et l'évolutivité. ▪ Certification automatisée de la sécurité et de la qualité des produits agro-alimentaires. ❖ Économiques : <ul style="list-style-type: none"> ▪ Réduction des coûts de transaction et numérisation des transactions. ▪ Les prix des produits sont plus raisonnables du fait de l'absence de monopole et de complot. ▪ La décentralisation offre la possibilité de négocier directement sans avoir besoin d'un tiers. ▪ Améliorer la collaboration des membres.

	<ul style="list-style-type: none"> ❖ Environnementaux : <ul style="list-style-type: none"> ▪ Offre une traçabilité dure qui réduit des déchets et les produits polluants. ❖ Sociaux : <ul style="list-style-type: none"> ▪ Augmente la satisfaction de vos clients en garantissant la sécurité et la qualité des aliments. ▪ Les contrats intelligents éliminent le besoin de tiers de confiance. ▪ Réduire les risques potentiels de marketing frauduleux et de contrefaçon. ▪ Les utilisateurs contrôlent toutes leurs informations de consommation. ❖ Technologiques : <ul style="list-style-type: none"> ▪ Offre des solutions pour les IoT comme la décentralisation, la transparence et la sécurité.
<p>Limites</p>	<ul style="list-style-type: none"> ❖ Organisationnelles : <ul style="list-style-type: none"> ▪ Dans les pays du tiers monde, le statut réglementaire de ces technologies est toujours incertain ainsi son cadre juridique est complexe. ❖ Environnementales : <ul style="list-style-type: none"> ▪ Une très grande consommation d'énergie. ❖ Sociales : <ul style="list-style-type: none"> ▪ Nécessite des compétences techniques élevées. ▪ Un changement complet vers un réseau décentralisé qui nécessite une adoption culturelle implique l'adhésion de ses utilisateurs et opérateurs. ❖ Technologiques : <ul style="list-style-type: none"> ▪ Nécessite l'intégration avec d'autres technologies (BDA, IoT, CPS). ▪ Offre des solutions qui nécessitent une réintégration et des modifications des systèmes ou le remplacement complet des solutions existants. ▪ Capacité de stockage et évolutivité limitées. ▪ Il est vrai qu'il existe des Blockchains privées fortes en termes de contrôle, sécurité et confidentialité, mais cette technologie reste exposée à des risques de cybersécurité et doit être mieux renforcée pour aider les utilisateurs à lui faire confiance. ▪ Traitement de beaucoup de transactions en temps réel est difficile en raison de la taille initiale des blocs et de l'intervalle de temps utilisé pour générer un nouveau bloc. ▪ Nécessite une connexion Internet (problèmes dans certains pays en développement).

4.3 Domaines de l'agriculture de précision

L'agriculture de précision, également connue sous le nom de gestion des cultures en fonction du site- est un concept de gestion agricole qui propose une approche globale du système pour gérer la variabilité spatiale et temporelle des cultures et des sols dans un champ afin d'accroître la rentabilité, d'optimiser le rendement et la qualité et de réduire les coûts et l'impact environnemental [62].

Une large gamme d'outils est disponible, basée sur la technologie GPS, les technologies de l'information, le Big data, l'intelligence artificielle, la gestion agricole et les connaissances économiques, ainsi que les technologies des capteurs et des applications. Jusqu'à présent, l'adoption et le développement de l'agriculture de précision dans les opérations agricoles sont encore en cours [63]. L'utilisation de l'agriculture de précision donne accès à une grande quantité de données qui peuvent être utilisées pour éclairer les décisions de gestion agricole.

Le terme d'agriculture 4.0 a récemment été inventé pour caractériser ce nouveau type d'agriculture basée sur l'information et les données.

L'agriculture moderne cherche à gérer les cultures dans des environnements contrôlés, pour améliorer la production des plantes ou de reproduire les conditions environnementales de zones géographiques spécifiques pour obtenir des produits importés localement. De plus, les variations météorologiques et les maladies qui ont un impact sur la production et la qualité des cultures peuvent être évitées grâce à une application complète des nouvelles technologies de surveillance et d'information, y compris le deep learning et l'analyse Big data. Il est désormais possible d'obtenir un état très précis des cultures et de former des décisions raisonnables pour contrôler les mauvaises herbes, détecter les maladies [64], gérer l'irrigation, modifier les facteurs climatiques ou classer les produits dans les milieux agricoles, ce qui optimise l'automatisation de la gestion précise et améliore la production des cultures tout en réduisant potentiellement les impacts environnementaux.

4.3.1 Détection des maladies

Le diagnostic des maladies des plantes par l'observation optique des symptômes sur les feuilles des plantes présente un degré de complexité élevé. En raison de cette complexité et du grand nombre de plantes cultivées et de leurs problèmes phytopathologiques, même les agronomes et les phytopathologistes expérimentés ne parviennent pas toujours à diagnostiquer avec succès des maladies spécifiques, ce qui les conduit à des conclusions et des traitements erronés [65].

L'existence d'un système informatique automatisé pour la détection et le diagnostic des maladies des plantes offrirait une aide précieuse à l'agronome à qui l'on demande d'effectuer de tels diagnostics par l'observation optique des feuilles des plantes infectées. En tant que système de vérification dans le diagnostic des maladies, un système automatique conçu pour identifier les maladies des plantes par l'apparence et les symptômes visuels de la plante pourrait être d'une grande aide pour les agriculteurs. De nombreux efforts ont été appliqués au diagnostic rapide et précis des maladies des feuilles en utilisant des systèmes de traitement des images numériques [65]. Tout cela est, bien sûr, valable à condition que le système puisse atteindre des niveaux élevés de performance dans la détection et le diagnostic de maladies spécifiques dans des conditions réelles. Avec le développement des systèmes informatiques au cours des dernières années, les applications d'intelligence artificielle liées à l'apprentissage automatique ont connu une croissance exponentielle, ce qui a conduit au développement de nouvelles méthodologies et de nouveaux modèles, qui forment une nouvelle stratégie de détection des maladies des plantes [66]. L'apprentissage profond a fait d'énormes progrès au cours des dernières années. Il est désormais capable d'extraire des représentations de caractéristiques utiles à partir d'un grand nombre d'images d'entrée. L'apprentissage profond offre la possibilité aux détecteurs d'identifier les maladies des cultures de manière rapide et précise, ce qui permettra non seulement d'améliorer la précision de la protection des plantes, mais aussi d'élargir le champ d'application de la vision par ordinateur dans le domaine de l'agriculture de précision [66]. La figure 1-7 identifie les types de maladies du concombre à partir des signes qui apparaissent sur ses feuilles.



Figure 1- 7: Images de quatre maladies du concombre

4.3.2 Classification des cultures

Les agriculteurs et les parties prenantes doivent prendre des décisions éclairées sur de nombreuses activités connexes. De nombreuses informations sont nécessaires pour prendre ces décisions, comme la quantité de chaque type de culture plantée dans chaque zone [68]. Les cartes de cultures sont généralement classées en deux catégories : les cartes de saison (générées pendant

la saison de croissance) et les cartes d'après-saison (générées après la saison de croissance). Les cartes en cours de saison sont beaucoup plus utiles pour prendre des décisions opportunes et présentent des avantages financiers plus importants que les cartes d'après-saison. La figure 1-8 montre une carte de classification des types de cultures créée par la technique de télédétection.

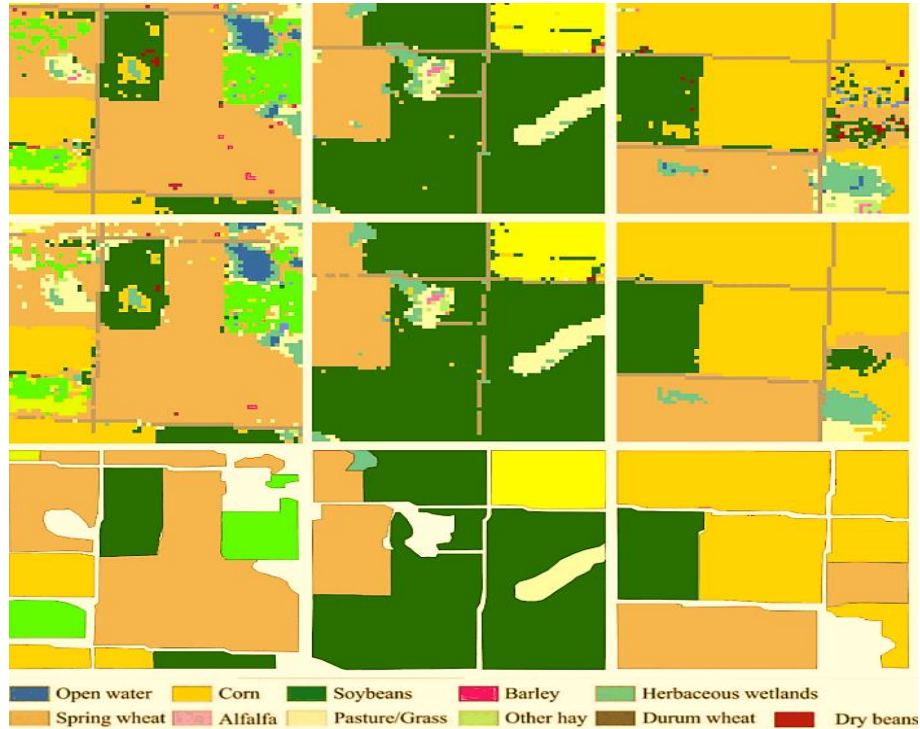


Figure 1- 8: Classification des types de cultures

La disponibilité croissante de données provenant d'observations satellitaires récurrentes et à long terme a suscité un vif désir de la part de la communauté agricole d'utiliser les données satellitaires pour créer des cartes des cultures sur de vastes zones géographiques [69].

Cependant, la plupart des parties prenantes des cultures, telles que les agriculteurs, les départements agricoles, les marchés alimentaires et les compagnies d'assurance ont besoin de cartes des cultures en cours de saison pour les aider à prendre des décisions opportunes [70]. La réalisation de cartes précises en cours de saison a été un grand défi pour la communauté. Après avoir observé les caractéristiques spectrales des cultures au cours de la saison de croissance, il semble possible de combiner les données collectées annuellement avec l'imagerie satellitaire pour générer un produit cartographique annuel des cultures, de générer des inventaires en cours de saison avec une imagerie de télédétection à grande échelle et des données limitées observées sur le terrain.

4.3.3 Irrigation de précision

De plus en plus de planificateurs et d'associations d'agriculteurs sont conscients de l'importance de l'audit et de l'efficacité de l'utilisation de l'eau, car les ressources en eau sont de plus en plus rares. Des efforts pour utiliser des méthodes de micro-irrigation telles que l'arrosage et le goutte-à-goutte ont été faits au cours des trois dernières décennies dans de nombreuses régions du monde [71].

Il n'existe pas de méthode d'irrigation idéale qui puisse convenir à toutes les conditions météorologiques, à la structure du sol et à la variété des cultures. On constate que les agriculteurs doivent supporter d'énormes pertes financières en raison de prévisions météorologiques erronées et de méthodes d'irrigation incorrectes. Compte tenu du besoin réel d'améliorer l'efficacité des systèmes d'irrigation et de prévenir la mauvaise utilisation de l'eau, l'objectif est de développer un système intelligent de programmation de l'irrigation qui permettra aux agriculteurs d'optimiser l'utilisation de l'eau et d'irriguer uniquement là où c'est nécessaire et aussi longtemps que nécessaire. La figure 1-9 montre les composants et le mode de fonctionnement d'un système d'irrigation intelligent.

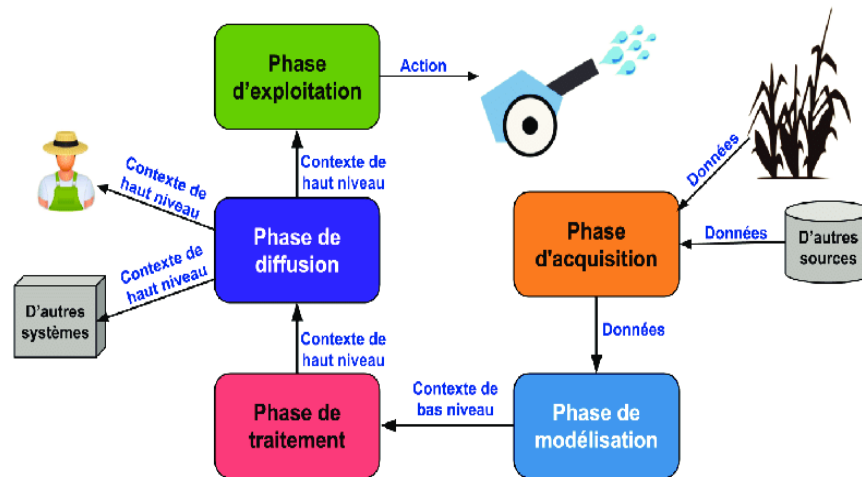


Figure 1- 9: Le cycle de fonctionnement d'un système d'irrigation intelligent

L'irrigation de précision est un concept nouveau dans le monde de l'irrigation. L'irrigation de précision implique l'application exacte et précise de l'eau pour répondre aux exigences spécifiques des plantes individuelles ou des unités de gestion et minimiser l'impact environnemental négatif. La définition communément acceptée de l'irrigation de précision est la gestion durable des ressources en eau qui implique l'application de l'eau à la culture au bon moment, à la bonne quantité, au bon endroit et de la bonne manière, ce qui permet de gérer la variabilité de l'eau sur

le terrain et d'augmenter la productivité des cultures et l'efficacité de l'utilisation de l'eau tout en réduisant les coûts énergétiques de l'irrigation.

4.3.4 Élevage de précision

L'objectif d'élevage de précision (EP) est de gérer les animaux individuels par un suivi continu en temps réel de la santé, du bien-être, de la production/reproduction et de l'impact environnemental. Le mot "continu" signifie dans ce cas que la technologie EP mesure et analyse chaque seconde, 24 heures sur 24 et 7 jours sur 7. Les agriculteurs sont avertis lorsque quelque chose ne va pas, de telle sorte que le système EP leur indique le ou les animaux qui nécessitent leur attention à ce moment-là. La surveillance peut être effectuée par une caméra et des analyses d'images en temps réel, par un microphone et des analyses sonores en temps réel, ou par des capteurs autour ou sur l'animal, comme indiqué dans la figure 1-10.

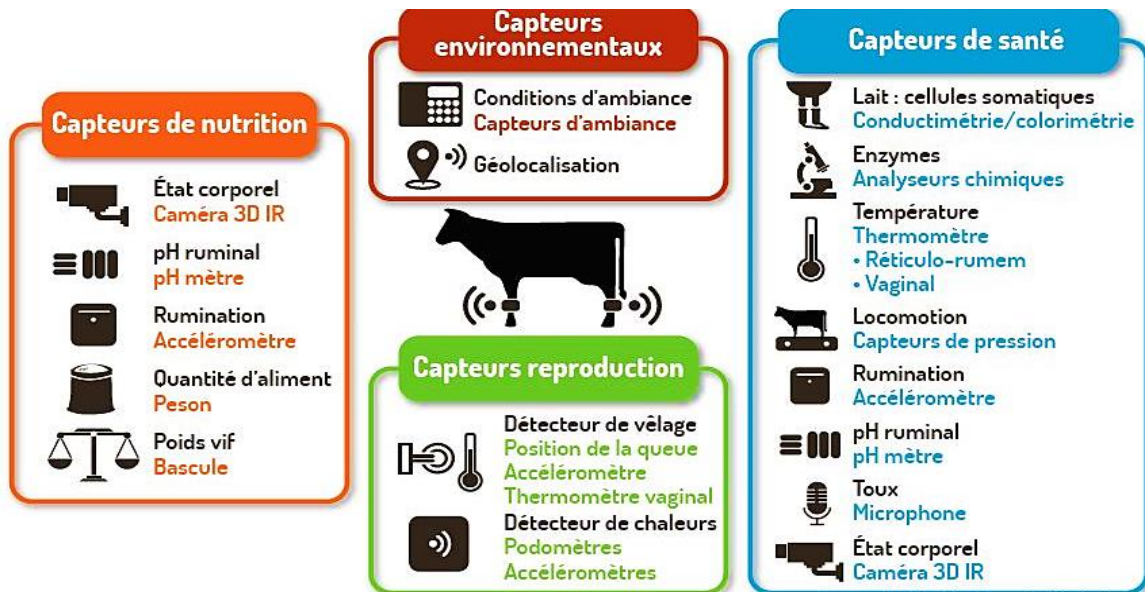


Figure 1- 10: Systèmes d'élevage de précision

L'approche générale pour collecter des données de terrain en temps réel, connues sous le nom de bio-sinaux, sur l'animal consiste à utiliser des capteurs (par exemple, mesure de la température, position GPS, données d'accéléromètre, etc.), l'analyse d'images en temps réel ou l'analyse du son. Ces deux dernières techniques présentent des avantages tels que : l'absence de contact physique, l'absence de risque d'infection ou de transfert de maladie, l'absence de risque d'influencer la réponse de l'animal pendant la mesure, l'absence de nécessité de récupérer les capteurs sur des animaux vivants, la réduction des coûts puisqu'une caméra ou un microphone peut surveiller un grand groupe d'animaux.

Les réactions des animaux pouvant être très rapides, il est inutile de réaliser une enquête une fois par an, une fois par mois ou par semaine, ou même deux fois par jour. Nous avons besoin d'un outil de suivi et de gestion en continu. En fonction de la variable surveillée, le mot "continu" peut signifier toutes les secondes (par exemple, pour la surveillance du stress) ou une fois par jour (par exemple : pour la surveillance du poids). Lorsque les technologies PLF sont installées dans les bâtiments d'élevage, elles génèrent une énorme quantité de données. C'est pourquoi nous utilisons le stockage en nuage et l'analyse des données en temps réel qui permet de calculer des informations pertinentes à partir des données, de préférence sur ou près de l'animal individuel.

4.3.5 Détection des mauvaises herbes

Les mauvaises herbes sont contrôlées chimiquement en appliquant des herbicides sur le champ. Les mauvaises herbes peuvent également être contrôlées mécaniquement ou thermiquement, mais cela exige une plus grande précision que le désherbage chimique. Par conséquent, le rendement est beaucoup plus faible. Ainsi, le désherbage chimique est le traitement préféré de la plupart des agriculteurs conventionnels. Cependant, une pression croissante s'exerce sur les exploitations agricoles pour qu'elles réduisent l'utilisation des herbicides, en raison de l'effet indésirable que ceux-ci peuvent avoir sur l'environnement. Cela pousse l'agriculteur à avoir inspecté ses champs avant de les pulvériser et à n'utiliser que des dosages adaptés aux besoins spécifiques de son exploitation. C'est un processus très fastidieux et donc un processus automatisé est nécessaire pour détecter le site des mauvaises herbes et ainsi réduire la charge de travail de l'agriculteur.

Sur cette base et afin de rationaliser l'utilisation de ces herbicides, il serait préférable de détecter les mauvaises herbes dans les cultures avant d'utiliser les herbicides, alors un modèle de deep learning peut aider à choisir l'herbicide parfait et à l'utiliser uniquement dans les zones où les mauvaises herbes sont présentes. Ne pouvant guère couvrir toutes ces composantes agricoles, nous nous sommes intéressés, dans ce travail de recherche, à la détection des mauvaises herbes, qui s'impose comme étant l'une des préoccupations majeures de l'agriculteur qui a pour souci clé la gestion optimale de ses champs. Comme le montre la figure 1-11, le système peut identifier les zones couvertes de mauvaises herbes en temps réel et peut également donner les espèces spécifiques de ces plantes.

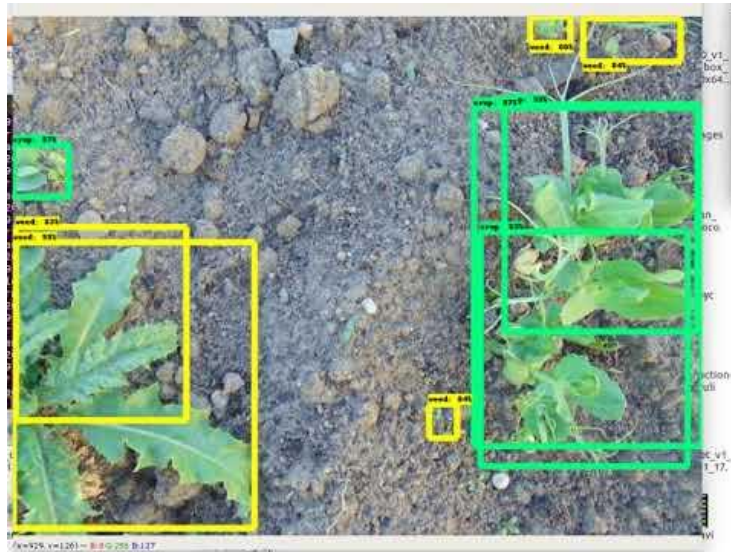


Figure 1- 11: Détection de mauvaises herbes

4.3.6 Autres filières

Il existe de nombreux autres domaines que la modernisation et la digitalisation ont atteints à la lumière de la transformation numérique de l'agriculture. Nous mentionnons ici l'utilisation de télédétection pour analyser et déterminer le pourcentage d'occupation des terres agricoles, l'utilisation de la technologie pour surveiller en temps réel et à distance les conditions de l'environnement, exploiter le pouvoir des systèmes avancés pour le suivi et le traçage des objets, l'utilisation de systèmes intelligents pour obtenir des données agricoles et leur exploitation dans la commercialisation des produits agricoles, l'utilisation des analyses profondes pour prendre la décision appropriée dans le domaine agricole.

4.4 Agriculture digitale au Maroc

L'adoption de nouvelles technologies dans le secteur agricole marocain est devenue aujourd'hui une nécessité impérieuse. D'une part, pour suivre la tendance mondiale de l'innovation et rester compétitif, d'autre part, pour relever des défis purement agronomiques, économiques et environnementaux. Au Maroc, l'agriculture innovante commence à gagner plus d'intérêt ces dernières années auprès des différents acteurs publics, privés et aussi au niveau des recherches scientifiques, tel qu'on trouve que le Maroc arrive en cinquième position au nombre de projets retenus dans le cadre du Programme de recherche PRIMA 2020 [72].

PRIMA est le plus grand programme de recherche et d'innovation de la région méditerranéenne. Le programme, qui a débuté en 2018 pour 10 ans, bénéficie d'un budget total de 494,5 millions d'euros, incluant 200 millions de la contribution européenne. Il a pour but de faire en sorte de

consolider la coopération en matière de recherche et d'innovation dans ces pays, afin de développer des solutions innovantes pour contribuer aux défis de la production alimentaire durable et de la sécurité de l'eau dans la région [73].

Selon la banque mondiale dans son rapport intitulé "Morocco Digital and Climate Smart Agriculture Program", sous l'impulsion des secteurs public et privé, la transformation numérique de l'agriculture marocaine a commencé. Le secteur connaît diverses améliorations numériques liées à l'imagerie satellitaire, aux technologies basées sur l'internet et la téléphonie mobile, aux réseaux IoT et aux plateformes de commerce électronique [74].

Les innovations technologiques dans le secteur agricole présentent plusieurs enjeux. La littérature sur les technologies de l'agriculture de précision donne un large aperçu sur ces enjeux. En se basant sur cette littérature, nous avons identifié trois enjeux majeurs de l'adoption des nouvelles technologies (NT) dans le secteur agricole, à savoir : des enjeux agronomiques, économiques et environnementaux.

L'enjeu agronomique réside dans le fait que les nouvelles technologies permettent aujourd'hui aux agriculteurs de mieux s'adapter aux contraintes météo et aux types de sols de leurs parcelles. La référence [75] a évalué l'impact des capteurs d'humidité du sol pour réduire la durée du profilage de l'humidité du sol. Les résultats ont montré le grand potentiel des capteurs à faible coût qui a permis d'obtenir un profilage haute résolution pour une irrigation économisant l'eau.

Les enjeux économiques relatifs aux NT sont importants, puisque celles-ci ont des effets directs sur le revenu agricole. L'utilisation des NT impacte le rendement. Les résultats montrent que l'adoption des NT génère des bénéfices plus élevés avec des rendements plus importants avec une utilisation optimale des intrants.

Il y a ensuite des enjeux environnementaux liés à l'utilisation des NT puisqu'elles visent à diminuer l'empreinte écologique de l'activité agricole. Par exemple, on peut ainsi adapter l'utilisation de produits phytosanitaires en fonction des stricts besoins des cultures. L'article [76] s'est intéressé à l'impact de la fertilisation azotée basée sur la technologie satellite. Les résultats ont montré que cette technologie a permis de réduire l'impact environnemental de 11,0% à 13,6% par rapport à une application standard.

Lors d'un forum organisé à Meknès sous le thème "La transformation numérique pour un secteur agricole prometteur et pourvoyeur d'emplois pour les jeunes ruraux", le ministre marocain de l'Agriculture, a déclaré que la numérisation était un moyen d'atteindre le développement durable.

Malgré le succès du Maroc dans la transformation numérique dans le domaine agricole, il est encore au début du chemin, il a besoin de s'occuper de certains défis auxquels il est confronté.

Selon le ministre de l'Agriculture, "le Maroc a le potentiel pour devenir un centre important dans la numérisation de l'agriculture, compte tenu de l'infrastructure de communications performantes et de l'accès à l'information et aux données grâce aux satellites Mohammed VI". La transformation numérique de l'agriculture permettra d'améliorer le pouvoir d'attraction du secteur et d'ouvrir des possibilités d'emploi pour les jeunes sur un marché du travail qui est devenu plus dépendant de la technologie. Lors de la 14e session du Salon international de l'agriculture, le ministre de l'Agriculture a déclaré aussi que "les meilleures entreprises internationales ont amélioré leurs performances, en particulier dans l'agriculture ciblée, de sorte que nous parlons aujourd'hui de fermes numériques qui peuvent être gérées et contrôlées à distance".

5. Conclusion

L'agriculture digitale offre la possibilité d'utiliser la technologie pour convertir des données précises en connaissances exploitables susceptibles de stimuler et de soutenir la prise de décision complexe dans la ferme et tout au long de la chaîne de valeur. L'agriculture numérique reflète le passage d'une gestion généralisée des ressources agricoles à une gestion hautement optimisée, individualisée, en temps réel, hyper connectée et pilotée par les données. La numérisation et les nouvelles technologies apportent à la fois des opportunités, des défis et des risques. Déjà commencée, la transformation du secteur agricole par les données modifie les marchés agroalimentaires et les relations dans les chaînes qui s'y rapportent. Ce chapitre présente un état de l'art sur la digitalisation de l'agriculture, nous avons fourni un aperçu sur les formes de digitalisation en agriculture, nous avons également fourni un benchmark de différentes technologies actuelles relatives au domaine de recherche choisi avec leurs impacts et défis. Nous avons apporté un aperçu général des recherches dans ce domaine, afin de préciser la voie à suivre pour apporter davantage de contributions scientifiques. Nous avons également donné un aperçu de la digitalisation dans l'agriculture marocaine. Après cet aperçu sur la transformation digitale de l'agriculture, nous aborderons dans le chapitre suivant l'intelligence artificielle avec ses sous-domaines, comme les moyens les plus importants dont nous avons identifié ses nombreux avantages dans ce chapitre.

CHAPITRE

II

**CHAPITRE II : ÉTUDE ET BENCHMARK DES
TECHNIQUES ET ALGORITHMES DE
L'INTELLIGENCE ARTIFICIELLE**

1. Introduction

Le monde évolue vers une utilisation généralisée de l'intelligence artificielle. Le potentiel de l'intelligence artificielle est plus grand que nous ne pouvons l'imaginer. Certains prétendent que c'est l'avenir et certains s'inquiètent de ses implications, mais une chose est sûre : le monde évolue dans le sens d'une utilisation généralisée de l'intelligence artificielle. En pratique, la majorité des publications explorées se sont mêlées à différentes technologies IT utilisées en agriculture, dont on peut retenir l'IA qui est considérée comme étant une technologie révolutionnaire appliquée dans plusieurs domaines, notamment en agriculture à travers des algorithmes spécifiques. Par ailleurs, nous avons constaté également que le DL et le ML sont des approches de l'intelligence artificielle les plus adoptées en agriculture digitale en vue d'un traitement efficace des cultures, ou dans d'autres filières non moins importantes. Les articles que nous avons exploités dans ce domaine nous révèlent des propositions d'amélioration ainsi des détails techniques qui diffèrent selon le problème traité. Il y a ceux qui s'appuient sur des modèles d'apprentissage en profondeur basés sur les réseaux neuronaux convolutifs, qui sont les dominants, d'autres s'appuient sur des améliorations des réseaux de deep learning. Par conséquent DL et ses différents types et architectures ont été beaucoup utilisés dans le domaine de l'agriculture, d'où notre intérêt pour appréhender davantage dans les différents algorithmes de DL utilisés dans ce domaine.

Ce chapitre est considéré comme une deuxième partie du chapitre précédent, dans lequel nous avons entrepris une analyse documentaire de 35 articles cités précédemment pour découvrir les différentes approches axées autour de l'utilisation des technologies dans l'agriculture, Ce nombre d'articles est tout ce que nous avons pu obtenir en utilisant des mots-clés liés au sujet de la recherche, nous nous sommes contentés d'articles qui n'ont pas dépassé cinq ans depuis leur publication. À travers ces études, nous avons identifié divers techniques, approches et algorithmes de machine learning et de deep learning qui contribuent à la transformation digitale de l'agriculture et extrait divers détails techniques pouvant être adoptés pour créer des algorithmes innovants de deep learning. Nous avons également examiné les filières et les processus agricoles sur lesquels nous pourrions appliquer ces techniques. Nous avons exploré aussi les moyens possibles d'obtenir des données de l'entraînement de ces modèles de deep learning. Afin de mieux comprendre ces techniques de transformation digitale et de choisir celle qui convient, nous avons mené des benchmarks de différentes méthodes, techniques et approches et leurs domaines d'utilisations. Les résultats de cette étude ont été publiés dans un journal indexé Scopus [77].

2. Intelligence artificielle

L'intelligence artificielle est un concept assez général, elle regroupe en son sein pas mal de domaines et d'approches différentes et variées qui ont commencé à se développer depuis les années 50. L'intelligence artificielle est un concept qui fait référence à toute méthode, approche et outils permettant à un ordinateur ou à une machine d'afficher un certain niveau de sagesse. En d'autres termes, l'intelligence artificielle est une enveloppe qui comprend une longue liste d'outils, de méthodes et de moyens conçus pour donner à un ordinateur des capacités similaires à celles des humains, par exemple : la reconnaissance faciale. L'intelligence artificielle comme nous l'avons dit, a commencé déjà dans les années cinquante et dans ses premières années consistait principalement en des algorithmes construits selon certaines bases de données, c'est-à-dire que chaque changement d'information nécessite un changement de système, ce que l'on appelle le "réapprentissage".

L'intelligence artificielle divers domaines sous-jacents comme les statistiques, les mathématiques et la programmation. Les différentes étapes et procédures de cette approche des impliquent l'extraction, la manipulation, la visualisation et la maintenance des données afin de prévoir l'occurrence d'événements futurs. Un scientifique des données doit également avoir une bonne connaissance des algorithmes d'apprentissage automatique.

Dans la définition de l'intelligence artificielle (IA), nous avons noté qu'il s'agit d'un concept général qui comprend de nombreux sous-domaines. L'apprentissage automatique, on l'appelle aussi machine learning ou ML en abrégé et le deep learning sont des domaines les plus courants. Dans le chapitre précédent, nous avons présenté les différentes forces et faiblesses de cette technologie, notamment dans le domaine agricole. On peut dire qu'il s'agit d'une technologie puissante comparable à la capacité humaine dans l'intervention et la prise de décision. En d'autres termes, cette technologie donne aux systèmes informatiques la capacité de prendre des décisions intelligentes en temps réel.

Comme la figure 2-1 le montre, entre les trois concepts : Intelligence artificielle, machine learning et deep learning, il existe un lien direct et important. Intelligence artificielle comprend l'apprentissage des machines ML qui comprend l'apprentissage en profondeur. À la différence du machine learning, le deep learning est un modèle d'apprentissage beaucoup plus autonome. Il permet d'automatiser certaines tâches.

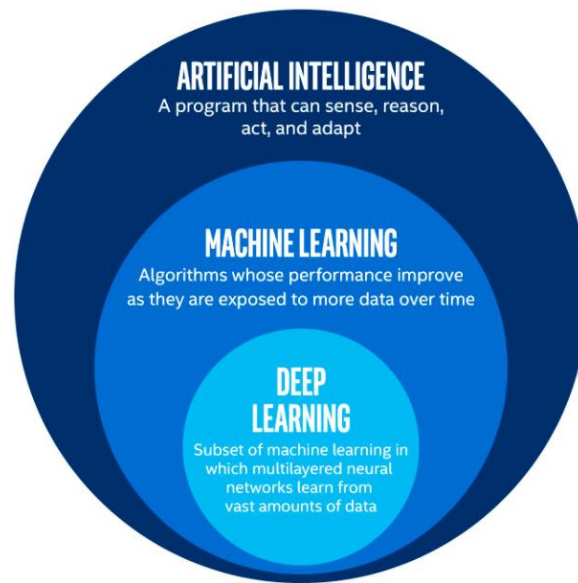


Figure 2- 1: Relation entre IA, ML et DL

Lorsque vous explorez ce domaine lié à l'intelligence artificielle, vous devez rencontrer un ensemble de termes étroitement liés à ce domaine et nécessitant une compréhension pour en comprendre leurs objectifs, nous présentons dans le tableau 2-1 les plus importants de ces termes.

Tableau 2- 1. Définitions des termes courants en intelligence artificielle

Terme	Définition
Domaine d'expertise	<ul style="list-style-type: none"> La compréhension des problèmes du monde réel dans un domaine donné (par exemple, l'agriculture) qui aide à encadrer et à contextualiser l'application de la science des données pour résoudre ces problèmes.
Machine Learning	<ul style="list-style-type: none"> Le domaine d'étude qui se concentre sur la façon dont les ordinateurs apprennent à partir de données et le développement d'algorithmes qui rendent cet apprentissage possible.
Data Mining	<ul style="list-style-type: none"> L'extraction de connaissances à partir de données via des algorithmes d'apprentissage automatique qui intègrent principes de la science des données.
Features	<ul style="list-style-type: none"> Les éléments de données, également appelés variables indépendantes, utilisés pour former un modèle. Ces Features peuvent être des transformations simples des données brutes (par exemple, la mesure d'un fruit) ou des transformations complexes telles que celles effectuées par les réseaux neuronaux.
Outcomes	<ul style="list-style-type: none"> Les éléments de données, également appelés variables dépendantes, représentent la cible de l'apprentissage dans un modèle d'apprentissage supervisé. Les résultats peuvent être catégoriques (par exemple, oui/non) ou continus (par exemple, la durée).
Supervised Learning	<ul style="list-style-type: none"> Algorithmes utilisés pour découvrir la relation entre un ensemble de caractéristiques et un ou plusieurs résultats connus.
Unsupervised	<ul style="list-style-type: none"> Les algorithmes qui sont utilisés pour découvrir des modèles ou des

Learning	regroupements naturels dans les données, sans cibler un résultat spécifique.
Model training	<ul style="list-style-type: none"> Le processus par lequel les algorithmes d'apprentissage automatique développent un modèle des données en apprenant les relations entre les caractéristiques et, dans l'apprentissage supervisé, entre les caractéristiques et les résultats.
Model validation	<ul style="list-style-type: none"> Le processus de mesure de l'adéquation d'un modèle à des données nouvelles et indépendantes. Par exemple, l'évaluation de la performance d'un modèle supervisé pour prédire un résultat dans de nouvelles données. Cette approche est également appelée test de modèle.
Overfitting	<ul style="list-style-type: none"> Le phénomène qui se produit lorsqu'un algorithme apprend à partir des caractéristiques des données d'apprentissage, généralement appelées bruit. Les données bruitées ne représentent pas la vérité généralisable (généralement appelée signal) qui explique les relations entre les caractéristiques et les résultats. Le surajustement entraîne généralement une mauvaise performance du modèle dans un ensemble de données de validation indépendant.
Structured data	<ul style="list-style-type: none"> Données (généralement discrètes ou numériques) qui sont faciles à rechercher, à résumer, à trier et à quantifier.
Unstructured data	<ul style="list-style-type: none"> Les données qui ne se conforment pas à une structure préspecifiée, comme un récit écrit, des images, des vidéos ou du son. Les données non structurées sont généralement plus difficiles à rechercher, à trier et à quantifier.

2.1 Machine Learning

L'apprentissage automatique est une approche qui vous permet "d'apprendre" à votre ordinateur à effectuer une variété de tâches. Avec l'abondance des ensembles de données disponibles, la demande du machine learning est en hausse. De nombreux secteurs, de l'agriculture à l'armée, appliquent le machine learning pour extraire des informations pertinentes.

L'objectif du machine learning est d'apprendre à partir des données. De nombreuses études ont été réalisées sur la manière de faire apprendre les machines par elles-mêmes [78][79].

Il existe actuellement de nombreux algorithmes dans la catégorie machine learning comme SVM et KNN. Bien qu'ils soient parfaits pour certains problèmes comme la création de groupes d'informations avec un dénominateur commun, ces algorithmes peuvent ne pas être vraiment pertinents pour d'autres problèmes. L'algorithme KNN, par exemple, n'est pas très efficace lorsqu'il s'agit d'identifier des objets dans des images. Les algorithmes de machine learning sont généralement divisés en deux catégories : supervisés et non supervisés [80]. Les algorithmes semi-supervisés représentent un hybride des deux, mais ont été moins souvent utilisés pour résoudre des problèmes.

❶ Algorithmes d'apprentissage supervisé :

Les algorithmes d'apprentissage supervisé sont utilisés pour découvrir la relation entre les variables d'intérêt et un ou plusieurs résultats cibles [81]. Pour les problèmes supervisés, le ou les résultats cibles doivent être connus. Par exemple, si les chercheurs veulent savoir si un ensemble de caractéristiques de planètes (par exemple : la longueur des pétales, la largeur des pétales) peut prédire le type de planète, ils peuvent appliquer un algorithme d'apprentissage supervisé à un ensemble de données dans lequel chaque enregistrement de planète contient l'ensemble des caractéristiques et une étiquette spécifiant leur résultat [82].

❷ Algorithmes d'apprentissage non supervisé :

Les algorithmes d'apprentissage non supervisé sont utilisés pour découvrir des modèles ou des regroupements naturels dans les données, sans cibler un résultat spécifique [80]. Le cas d'utilisation le plus convaincant de l'apprentissage non supervisé en agriculture est la détection des mauvaises herbes, dans laquelle l'objectif est de découvrir des sous-ensembles de la planète qui partagent des caractéristiques similaires et sont, en théorie, plus susceptibles de répondre à la mauvaise herbe ciblée. Le tableau 2-2 présente les différentes classes d'algorithmes de l'intelligence artificielle et donne plus de détails.

Tableau 2- 2. Exemples d'utilisation d'algorithmes

Classe d'algorithme	Exemples	Description
Régression classique	Régression linéaire, régression logistique	<ul style="list-style-type: none"> La régression linéaire est un algorithme d'apprentissage supervisé qui modélise la relation entre une ou plusieurs caractéristiques et un résultat continu en ajustant une ligne de régression qui minimise la somme de tous les résidus, qui sont les distances entre chaque caractéristique des données d'apprentissage et la ligne ajustée pour les modéliser. La régression logistique est une généralisation du modèle linéaire qui utilise la fonction logistique pour estimer la probabilité d'un résultat binaire. Pour ce faire, la courbe ajustée en forme de sigmoïde de la fonction logistique fait correspondre les valeurs des caractéristiques à une probabilité comprise entre 0 et 1.
Régression régularisée	Lasso, régression de crête, filet élastique	<ul style="list-style-type: none"> Une extension des algorithmes de régression classiques dans laquelle une pénalité est imposée au modèle ajusté afin de réduire sa complexité et de diminuer le risque d'Overfitting.

Arbre de décision	Arbres de classification et de régression, forêt aléatoire (Random Forest), arbres à gradient boosté	<ul style="list-style-type: none"> ▪ Une classe d'algorithme d'apprentissage supervisé basée sur les arbres de décision. Les arbres de décision sont une séquence de divisions de "conditions" qui sont dérivées en séparant itérativement les données en groupes basés sur la relation des caractéristiques avec le résultat. Random Forest et les arbres renforcés par le gradient sont des exemples de modèles d'ensemble. Les modèles d'ensemble combinent les résultats de plusieurs modèles entraînés pour estimer un résultat.
Machine à vecteurs de support(SVM)	Linéaire, Polynôme, noyau de base radiale	<ul style="list-style-type: none"> ▪ Une classe d'algorithmes d'apprentissage supervisé qui représente les données dans un espace de caractéristiques multidimensionnel, puis ajuste un "hyperplan" qui sépare au mieux les données en fonction des résultats d'intérêt.
k plus proches voisins (K-nearest Neighbors)	k plus proches voisins (K-nearest Neighbors)	<ul style="list-style-type: none"> ▪ Type d'algorithme d'apprentissage supervisé qui représente les données dans un espace de caractéristiques multidimensionnel et utilise des informations locales sur les observations les plus proches d'un nouvel exemple pour prédire le résultat de cet exemple.
Bayésien	Naïf Bayes, réseau bayésien	<ul style="list-style-type: none"> ▪ Classe d'algorithmes d'apprentissage supervisé qui utilisent le théorème de Bayes sur la probabilité conditionnelle, c'est-à-dire la probabilité qu'une chose se produise si une autre chose s'est déjà produite.
Réseau de neurones	Réseau de neurones artificiels, réseau de neurones profonds	<ul style="list-style-type: none"> ▪ Classe d'algorithmes non linéaires construits à l'aide de couches de nœuds qui extraient des caractéristiques des données et effectuent des combinaisons qui représentent au mieux la structure sous-jacente, généralement pour prédire un résultat. Les réseaux neuronaux peuvent être peu profonds (par exemple, un perceptron à deux couches) ou profonds (plusieurs couches), ce qui constitue la base du domaine de deep learning.
Analyse de cluster	K-moyennes(K-means), Analyse de cluster hiérarchique	<ul style="list-style-type: none"> ▪ Une classe d'algorithme d'apprentissage non supervisé qui utilise les structures inhérentes aux données pour organiser au mieux les données en sous-groupes ayant un maximum de points communs sur la base d'une certaine mesure de distance entre les caractéristiques.

2.2 Deep Learning

Deep learning étend le ML classique en ajoutant plus de "profondeur" (complexité) au modèle basé sur les réseaux de neurones artificiels (ANN). Chaque réseau neuronal est constitué

d'une séquence de couches dans lesquelles passent les données. Ces couches sont constituées de neurones et les neurones d'une couche sont connectés à la suivante (voir la figure 2-2).




Figure 2- 2: Réseau neuronal à perceptron multicouche

Ces connexions sont définies par ce que nous appelons un poids (une valeur numérique). Chaque couche possède également ce que l'on appelle un biais. Il s'agit simplement d'un neurone supplémentaire qui n'a aucune connexion et qui contient une seule valeur numérique. Les données commencent à la couche d'entrée et sont transformées au fur et à mesure qu'elles traversent les couches suivantes. Les données de chaque neurone suivant sont définies par la formule 2-1.

$$y = \left(\sum_{i=0}^n w_i x_i \right) + b \quad (\text{Éq. 2-1})$$

Nous prendrons cette somme à chaque neurone lorsque nous transmettrons des informations à travers le réseau. Ensuite, nous ajouterons ce qu'on appelle un biais à cette somme. Le biais nous permet de déplacer le réseau vers le haut ou vers le bas d'une valeur constante. C'est comme l'ordonnée à l'origine d'une ligne.

La fonction d'activation s'agit d'une fonction que nous appliquons à l'équation vue ci-dessus pour ajouter de la complexité et de la dimensionnalité à notre réseau. En transformant nos données dans une dimension plus élevée, nous pouvons généralement faire de meilleures prédictions plus complexes.

Les poids sont associés à chaque connexion de notre réseau neuronal. Chaque paire de nœuds connectés possède un poids qui indique la force de la connexion entre eux. Ces poids sont

essentiels au fonctionnement interne d'un réseau neuronal et seront modifiés au fur et à mesure de l'apprentissage du réseau neuronal. Le modèle tente de déterminer quels doivent être ces poids pour obtenir le meilleur résultat. Les poids commencent par une valeur constante ou aléatoire et changent au fur et à mesure que le réseau reçoit des données d'apprentissage.

En plus des poids, nous avons les biais, qui sont un autre élément important des réseaux neuronaux et qui seront aussi modifiés au fur et à mesure de l'apprentissage du modèle. Un biais est simplement une valeur constante associée à chaque couche. On peut le considérer comme un neurone supplémentaire sans connexion. Le but d'un biais est de déplacer une fonction d'activation entière d'une valeur constante. Cela permet une plus grande flexibilité lorsqu'il s'agit de choisir une activation et de former le réseau. Il y a un biais pour chaque couche.

Back propagation est l'algorithme fondamental de l'apprentissage des réseaux neuronaux. C'est lui qui modifie les poids et les biais de notre réseau pendant l'entraînement jusqu'à ce qu'il atteigne une haute précision. Un réseau de neurones contient de nombreuses couches. Chaque couche est préparée à faire une mission spécifique, le nombre de couches détermine le niveau de complexité, plus le nombre est grand, plus le réseau est complexe.

Dans un petit réseau de neurones, nous pouvons trouver trois couches : la couche d'entrée, la couche cachée et la couche de sortie. Ces couches sont constituées de nœuds, comme leur nom l'indique, chaque couche a une tâche donnée. Les couches d'entrée chargées de récupérer les données d'entrée et de les transmettre à la couche suivante. La couche cachée effectue toutes les tâches back-end du calcul ainsi que la transformation des données à l'aide de diverses fonctions qui permettent une représentation des données de manière hiérarchique, à travers plusieurs niveaux d'abstraction. La couche de sortie transmet le résultat final du calcul masqué. Comme il apparaît sur la figure 2-2. Deep learning a des applications variées allant du langage naturel au traitement d'image [83]. Un avantage important de deep learning est l'apprentissage des caractéristiques, c'est-à-dire l'extraction automatique des caractéristiques à partir de données brutes [84].

L'analytics est un terme anglais, qui désigne simplement l'analyse de données, dans un but d'en tirer des significations en but de prendre la décision. Il est possible d'associer ce terme à d'autres termes, afin de préciser les données, les outils et les approches dont il est question. On parlera par exemple de « web analytics » (ou « digital analytics », « data analytics », nous avons proposé de combiner les deux mots " deep analytics " parce que nous nous sommes appuyés sur l'analyse des données en vue d'en tirer des significations et faire des prédictions (prédire les mauvaises herbes) à l'aide de deep learning, nous utilisons le deep learning pour construire des modèles prédictifs

précis sur les données fournies. Le Deep Analytics a une expérience éprouvée dans la création d'algorithmes d'apprentissage automatique spécialisés et dans leur déploiement dans divers domaines. Les sous-sections suivantes présentent une brève introduction aux techniques de deep learning les plus populaires.

❶ Convolutional Neural Networks (CNN):

The Convolutional Neural Network est l'un des algorithmes d'apprentissage profond les plus populaires, notamment dans le domaine de la classification d'images. Les CNN ou ConvNet prennent une image en entrée et attribuent une importance (poids et biais apprenables) aux objets de l'image afin de pouvoir les différencier les uns des autres [85].

L'architecture générale d'un CNN est illustré sur la figure 2-3, elle est similaire à celle du schéma de connectivité des neurones dans le cerveau humain et s'inspire de la régulation du cortex visuel. Les neurones individuels ne répondent aux stimuli que dans une région limitée du champ visuel, appelée champ réceptif. Une combinaison de ces champs se chevauche pour couvrir l'ensemble de la zone visible.

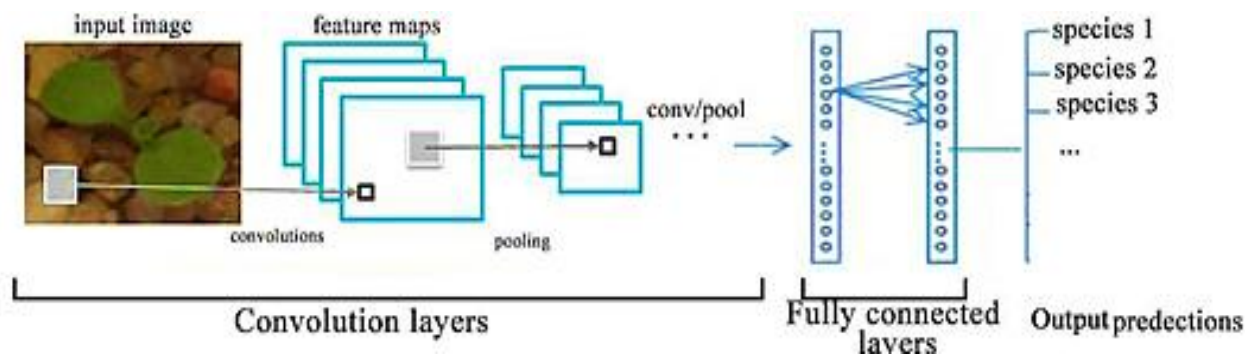


Figure 2- 3: Architecture standard du réseau de neurones convolutifs

Dans le domaine de la vision par ordinateur, une image en niveaux de gris est une matrice de pixels ou un tableau à deux dimensions avec des valeurs qui indiquent la luminosité, allant de 0 à 255. 0 signifie noir, 255 est blanc et tout le reste est une nuance de gris. La couleur est représentée par une troisième dimension de profondeur, 3, pour représenter les couleurs fondamentales [rouge, vert et bleu].

En termes simples, le CNN extrait la caractéristique de l'image et la convertit en une dimension inférieure sans perdre ses caractéristiques en faisant passer l'image par un ensemble de couches, ces couches définissant l'architecture de l'algorithme. La figure 2-4 met en exergue ce processus de l'extraction des features utilisant un filtre de 3x3.




Figure 2- 4: Convolution d'une image de 5×5×1 avec un filtre de 3×3×1

Comme illustré sur la figure 2-3 une image d'entrée est passée dans la couche d'entrée. Ensuite l'image sera traitée par la couche de convolution pour extraire les caractéristiques de l'image. Tout d'abord, une partie de l'image est connectée à la couche de convolution, cette couche a pour objectif d'effectuer l'opération de convolution et calculer le produit scalaire entre le champ réceptif (c'est une région locale de l'image d'entrée qui a la même taille que celle du filtre) et le filtre qui est formé d'un ensemble de poids. Le résultat de l'opération est un entier unique du volume de sortie. Ensuite, nous faisons glisser le filtre sur le champ réceptif suivant de la même image d'entrée par un Stride, nous refaisons la même opération jusqu'à ce que nous ayons parcouru toute l'image. La sortie appelée les cartes de convolution sera l'entrée de la couche suivante.

Après l'extraction des caractéristiques, une fonction d'activation est appliquée à la carte de convolution pour traiter les données hautement non linéaires. Il existe plusieurs fonctions d'activation les plus utiliser sont :

- Logistique (ou marche douce, ou sigmoïde) c'est une fonction étendue entre 0 et 1 pour les grandes valeurs négatives de x le terme e^{-x} dans le dénominateur croît exponentiellement et $f(x)$ se rapproche de 0. Inversement, les valeurs positives élevées de x rétrécissent e^{-x} à 0, donc $\sigma(x)$ se rapproche de 1, cette fonction est présentée par la formule 2-2.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (\text{Éq. 2-2})$$

- Unité de rectification linéaire ReLU ($y = \max(x, 0)$) prend en entrée n'importe quel nombre réel et transforme essentiellement tout ce qui est inférieur à zéro en zéro et tout ce qui est supérieur à zéro reste inchangé.

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (\text{Éq. 2-3})$$

La couche Pooling est utilisée pour réduire le volume spatial de l'image d'entrée après convolution, elle fonctionne de la même manière que les couches convolutives, c'est-à-dire qu'elles extraient des fenêtres de la carte des caractéristiques et renvoient une carte de réponse des valeurs maximales, minimales ou moyennes de chaque canal. Comme le montre la figure 2-5, il existe deux types de Pooling, Max-Pooling : La valeur de pixel maximale du lot est sélectionnée et Average-Pooling : la valeur moyenne de tous les pixels du lot est sélectionnée. Nous pouvons également ajouter ici les moyens de Min-Pooling où la valeur de pixel minimale du lot est sélectionnée. Nous pouvons utiliser plus d'une couche convolutionnelle et une couche de mise en commun avant d'utiliser la couche entièrement connectée pour effectuer la classification. La couche Softmax ou Logistique est la dernière couche du CNN. Elle se trouve à la fin de la couche entièrement connectée. La logistique est utilisée pour la classification binaire et la Softmax pour la multiclassification [86].




Figure 2- 5: Types de Pooling

② Recurrent Neural Network (RNN):

Il existe un autre type de réseau neuronal qui domine les problèmes d'apprentissage automatique qui impliquent des séquences d'entrées appelées réseaux neuronaux récurrents [87]. Jusqu'à présent, nous avons utilisé ce que l'on appelle des réseaux neuronaux à action directe. Cela signifie simplement que toutes nos données sont transmises en avant (toutes en même temps) de gauche à droite à travers le réseau. Cette méthode convenait parfaitement aux problèmes qu'on a des data ne dépend pas du temps ou de l'état précédent, mais elle ne fonctionnera pas très bien pour le traitement des données séquentiel. Après tout, même nous (les humains) ne traitons pas le

texte ou bien vidéo par exemple en une seule fois. Nous lisons mot par mot, de gauche à droite et gardons la trace du sens actuel de la phrase afin de pouvoir comprendre le sens du mot suivant. C'est exactement ce qu'un réseau neuronal récurrent est conçu pour faire. Lorsque nous parlons de réseau neuronal récurrent, nous voulons simplement dire qu'il s'agit d'un réseau qui contient une boucle. Un RNN traite un mot à la fois tout en conservant une mémoire interne de ce qu'il a déjà vu. Cela lui permet de traiter les mots différemment en fonction de leur ordre dans la phrase et de construire lentement une compréhension de l'entrée entière, un mot à la fois [88].

C'est pourquoi nous traitons nos données textuelles comme une séquence ! Pour que nous puissions transmettre un mot à la fois au RNN. Voyons à quoi pourrait ressembler un RNN.




Figure 2- 6: (À gauche) Un RNN. (À droite) Sa version déroulée

Ce que la figure 2-6 tente d'illustrer, c'est qu'une couche récurrente traite les mots ou les entrées un par un en les combinant avec les résultats de l'itération précédente. Ainsi, à mesure que nous progressons dans la séquence d'entrée, nous construisons une compréhension plus complexe du texte dans son ensemble. Ce que nous venons de voir s'appelle une couche RNN simple. Elle peut être efficace pour traiter des séquences de texte plus courtes pour des problèmes simples.

Il existe d'autres couches récurrentes (couches qui contiennent une boucle) qui fonctionnent beaucoup mieux qu'une simple couche RNN. Celle dont nous allons parler ici est appelée LSTM (Long Short-Term Memory). Cette couche fonctionne de manière très similaire à la couche RNN simple, mais ajoute un moyen d'accéder aux entrées de n'importe quel pas de temps dans le passé. Alors que dans notre couche RNN simple, l'entrée des timestamps précédents disparaissait progressivement au fur et à mesure que nous avançons dans l'entrée. Avec un LSTM, nous disposons d'une structure de données de mémoire à long terme stockant toutes les entrées vues

précédemment ainsi que le moment où nous les avons vues. Cela nous permet d'accéder à n'importe quelle valeur antérieure que nous voulons à n'importe quel moment. Cela ajoute à la complexité de notre réseau et lui permet de découvrir des relations plus utiles entre les entrées et le moment où elles apparaissent.

Parmi les problèmes de prédiction de séquence : One-to-Many: sortie de séquence, pour le sous-titrage d'image, Many-to-One : entrée de séquence, pour la classification des sentiments et Many-to-Many : séquence d'entrée et de sortie, pour la traduction automatique et Synched Many-to-Many : séquences synchronisées d'entrée et de sortie, pour la classification vidéo [89].

③ Benchmark des algorithmes de DL et de ML existants

Il s'agit d'une étude comparative dont une partie des résultats a été publiée [90]. Après avoir vu comment chaque réseau a été conçu, nous pouvons maintenant souligner les forces et les faiblesses de chacun. Les CNN sont préférés pour interpréter les données visuelles, les données rares ou les données qui ne viennent pas en séquence. Les réseaux de neurones récurrents, en revanche, sont conçus pour reconnaître des données séquentielles ou temporelles. Ils font de meilleures prédictions en considérant l'ordre ou la séquence des données en relation avec les nœuds de données précédents ou suivants. Les applications où les CNN sont particulièrement utiles incluent la détection de visage, l'analyse médicale, la découverte de médicaments et l'analyse d'images. Les RNN sont utiles pour la traduction linguistique, l'extraction d'entités, l'intelligence conversationnelle, l'analyse des sentiments et l'analyse de la parole. Comme récapitulatif des différentes études réalisées, le tableau 2-3 met en exergue les points forts et limites des algorithmes de machine learning et de deep learning les plus connus de chaque catégorie (Classification, régression, clustering). D'après ce benchmark, nous constatons que l'algorithme CNN jouit de beaucoup d'avantages avec moins d'inconvénients par rapport aux autres, d'où le choix de cet algorithme pour y appliquer plus d'optimisation en vue d'en tirer une meilleure rentabilité et performance dans la détection des mauvaises herbes.

Tableau 2- 3. Benchmark des algorithmes de ML et de DL existants

Algorithme	Avantage	Inconvénient
CNN	<ul style="list-style-type: none"> ▪ Exploite la méthode d'apprentissage empirique permet d'avoir des bons résultats. ▪ Simple et facile à implémenter. ▪ L'utilisation d'un poids unique associé aux signaux entrant 	<ul style="list-style-type: none"> ▪ Difficile à choisir l'architecture et les paramètres appropriés. ▪ L'ordre des couches affecte directement l'apprentissage. ▪ Il n'existe pas de méthode automatique pour choisir la

	<p>dans tous les neurones d'un même noyau de convolution</p> <ul style="list-style-type: none"> ▪ Il convient aux données spatiales telles que les images. ▪ Le réseau accepte des entrées de taille fixe et génère des sorties de taille fixe. 	<p>meilleure architecture possible pour un problème donné.</p> <ul style="list-style-type: none"> ▪ L'apprentissage est influencé par l'environnement matériel. ▪ Il n'est pas assez efficace pour les données non images.
RNN	<ul style="list-style-type: none"> ▪ Utilisé pour les données spatio-temporelles, également appelées données séquentielles. ▪ Efficace sur les données textuelles. ▪ Répandu sur les problèmes de prédiction de séquence. ▪ Peut utiliser sa mémoire interne pour traiter des séquences arbitraires d'entrées. 	<ul style="list-style-type: none"> ▪ Difficiles à former correctement (problème du gradient de disparition). ▪ Les prévisions de séries chronologiques sont faibles. ▪ Rarement utilisé seul. ▪ Nécessite toujours de lire toute une séquence pour produire une prédiction.
Naïf Bayes	<ul style="list-style-type: none"> ▪ Simple à comprendre et à construire ▪ Rapide et donne des résultats très efficaces dans des domaines variés ▪ Efficace avec peu de données. 	<ul style="list-style-type: none"> ▪ La performance est limitée quand il s'agit d'une grande quantité de données ▪ Une mauvaise performance s'il y a une grande corrélation entre les caractéristiques.
K-means	<ul style="list-style-type: none"> ▪ Implémentation facile. ▪ Gère des données complexes et inconnues ▪ Traite de données inconnues et complexes ▪ Les résultats sont rapides à produire et faciles à interpréter ▪ Efficace avec les datasets volumineux ▪ La possibilité de modifier l'algorithme en fonction d'un ensemble de données pour obtenir de meilleurs résultats 	<ul style="list-style-type: none"> ▪ L'algorithme ne donne pas la possibilité de choisir un ensemble optimal de clusters. ▪ Les résultats de clustering varient à chaque nouvelle exécution. ▪ Produit un cluster de taille uniforme. ▪ L'ordre des données lors de la construction de l'algorithme affecte les résultats. ▪ Nécessite la spécification de la valeur K. ▪ N'est pas possible de prévoir les k ou le nombre de clusters.
K-nearest Neighbors	<ul style="list-style-type: none"> ▪ Facile à implémenter. ▪ Très populaire ▪ Pas d'hypothèse sur les données affines, linéaires, etc. ▪ Résultats très importants dans des domaines de classification et de la régression. 	<ul style="list-style-type: none"> ▪ L'augmentation du nombre d'exemples d'apprentissage affecte la vitesse de l'algorithme (n'est pas efficace avec les données volumineuses). ▪ Nécessite le choix de la valeur de K. ▪ Sélectionner le bon K nécessite l'essai de plusieurs K

		<ul style="list-style-type: none"> ▪ L'étape de la prévision nécessite beaucoup de temps.
Random Forest	<ul style="list-style-type: none"> ▪ Pas d'Overfitting ▪ Meilleure performance que les autres algorithmes de même famille. ▪ Facile à configurer les paramètres. 	<ul style="list-style-type: none"> ▪ Entraînement plus lent ▪ Difficile à interpréter les résultats. ▪ Difficile à améliorer les résultats

3. Deep Learning pour le traitement de l'image et la vision par ordinateur

Les tâches de vision par ordinateur visent à permettre aux systèmes informatiques de voir, d'identifier et de comprendre automatiquement le monde visuel, en simulant la même chose que la vision humaine [91]. Les chercheurs en vision par ordinateur ont aspiré à développer des algorithmes pour ces tâches de perception visuelle, notamment la reconnaissance d'objets afin de déterminer si les données d'une image contiennent un objet spécifique, la détection d'objets afin de localiser les instances d'objets sémantiques d'une classe donnée et la compréhension de scènes afin de découper une image en segments significatifs à analyser.

Les chercheurs pensent que les systèmes informatiques peuvent aller au-delà de la reconnaissance ordinaire des objets et apprendre à révéler des détails et des idées du monde visuel en les entraînant à voir des trillions d'images et de vidéos à l'aide d'algorithmes de "deep learning" et de vision par ordinateur [92].

L'apprentissage profond est une classe particulière d'algorithmes d'apprentissage automatique, qui simplifie généralement le processus d'extraction et de description des caractéristiques par le biais d'un réseau neuronal convolutif multicouche (CNN) [93].

3.1 Classification des images

La classification d'images est une capacité biologiquement primaire du système de perception visuelle humain. Elle a été une tâche active et joue un rôle crucial dans le domaine de la vision par ordinateur, qui vise à classer automatiquement les images dans des classes prédéfinies. La classification d'images consiste à attribuer une étiquette à une image, comme l'identification des chats et des chiens dans une image ou la classification des chiffres montrée sur la figure 2-7.




Figure 2- 7: Classification des chiffres manuscrits

Le développement de la classification d'images a fait un grand bond en avant lorsque le jeu de données d'images à grande échelle "ImageNet" a été créé par Feifei Li en 2009 [92]. C'est presque au même moment que les technologies bien connues d'apprentissage profond ont commencé à montrer de grandes performances en matière de classification et ont fait leur entrée sur la scène de la vision par ordinateur.

Les modèles de classification basés sur le CNN profond sont beaucoup plus robustes que les autres méthodes conventionnelles en présence de variations à grande échelle. Il représente également une étape remarquable dans l'histoire moderne des réseaux neuronaux après une longue période de creux. Un modèle CNN profond typique se compose de plusieurs couches de convolution suivies de fonctions d'activation et de couches de mise en commun et de plusieurs couches entièrement connectées avant la prédiction. La structure profonde permet de faciliter les mécanismes de filtrage en effectuant des convolutions dans des cartes de caractéristiques multi-échelles, ce qui conduit à des caractéristiques hautement abstraites et discriminantes.

3.2 Détection d'objets

Historiquement, la plupart des efforts de recherche se sont concentrés sur la détection d'une seule catégorie d'objets donnés tels que les piétons [94] et les visages [95] en concevant un ensemble de caractéristiques appropriées (par exemple HOG, Harr-like, LBP, etc. [96]). Dans ces travaux, les objets sont détectés en utilisant un ensemble de modèles de caractéristiques prédéfinis correspondant à chaque emplacement dans l'image ou à des pyramides de caractéristiques. Des classificateurs standards tels que SVM et Adaboost sont souvent utilisés à cette fin [92]. Afin de

construire un système de détection d'objets robuste et polyvalent, la communauté des chercheurs a commencé à développer des ensembles de données multiclassées à grande échelle ces dernières années. Pascal-VOC 2007 [97], avec 20 classes et MS-COCO [98], avec 80 catégories d'objets, sont deux jeux de données emblématiques de la détection d'objets. La détection d'objets est généralement confondue avec la reconnaissance d'images, donc il est important que nous clarifions les distinctions entre eux. La reconnaissance d'image attribue une étiquette à une image. Une image d'herbe « Convolvulus » reçoit le label « Convolvulus ». Une photo de deux types reçoit toujours l'étiquette « Convolvulus ». La détection d'objets, quant à elle, dessine une boîte autour de chaque type d'herbe et étiquette la boîte « Convolvulus » comme celui sur la figure 2-8. Le modèle prédit où se trouve chaque objet et quelle étiquette doit être appliquée. De cette façon, la détection d'objet fournit plus d'informations sur une image que la reconnaissance.




Figure 2- 8: Détection des mauvaises herbes utilisant la technique "Object Detection"

La détection d'objets est inextricablement liée à d'autres techniques de vision par ordinateur similaires telles que la reconnaissance d'images et la segmentation d'images, en ce sens qu'elle nous aide à comprendre et à analyser des scènes dans des images ou des vidéos du champ agricole. Mais il existe des différences importantes. La reconnaissance d'image ne produit qu'une étiquette de classe pour un objet identifié et la segmentation d'image crée une compréhension au niveau des pixels des éléments d'une scène. Ce qui sépare la détection d'objets de ces autres solutions, c'est sa capacité unique à localiser des objets dans une image ou une vidéo. Cela nous permet ensuite de compter puis de suivre ces objets. Tout cela fait de la détection d'objets une technologie efficace et importante dans le domaine de la culture agricole.

Nous pouvons classer les détecteurs d'objets en deux catégories principales ; les détecteurs à deux étages, tels que Faster R-CNN, ont une étape de proposition de région d'intérêt et une autre

classification finale et une régression de la boîte englobante des objets prenant ces régions en entrée. Les détecteurs à une étape telle que YOLO, EfficientDet, Detectron2 considèrent la détection d'objets comme un simple problème de régression apprenant les probabilités de classe et les coordonnées de la boîte englobante à partir des images d'entrée.

R-CNN [99] est la première méthode en deux étapes parmi les premières techniques de détection d'objets génériques basées sur le CNN. Elle adopte AlexNet pour extraire un vecteur de caractéristiques de longueur fixe de chaque proposition de région redimensionnée, qui est le candidat objet généré par l'algorithme de recherche sélective. Inspiré par la mise en commun de la pyramide spatiale dans SPPnet [100] qui exploite les sorties de caractéristiques de longueur fixe pour des tailles d'images d'entrée arbitraires, Fast R-CNN [101] incorpore une couche de mise en commun ROI avant la couche entièrement connectée pour obtenir un vecteur de caractéristiques de longueur fixe pour chaque région proposée, de sorte qu'une seule opération de convolution est nécessaire pour l'image d'entrée.

Pour relever le défi susmentionné lié à la complexité de calcul, Faster R-CNN [102] propose en outre un réseau de proposition de région (RPN). Il intègre ensuite le RPN (pour la génération de propositions) et le Fast-RCNN (pour la classification des régions) dans une structure de réseau unifiée de bout en bout. RPN et Fast-RCNN partagent la plupart des couches de convolution. Les caractéristiques de la dernière couche partagée sont utilisées pour deux tâches distinctes (c'est-à-dire la génération de propositions et la classification des régions).

3.3 Segmentation des images

La classification d'images doit reconnaître les objets présents dans la scène visuelle (comme le montre l'exemple de la figure 2-9(a)), tandis que la détection d'objets révèle où se trouvent les objets (comme le montre l'exemple de la figure 2-9(b)).

Dans cette sous-section, nous nous concentrons sur le problème de la présentation exacte des objets dans la scène visuelle en utilisant la segmentation d'image.

La segmentation d'image est considérée comme une classification au niveau du pixel, qui vise à diviser une image en régions significatives en classant chaque pixel dans une entité spécifique. Dans la segmentation d'image traditionnelle, l'idée de fusion et de division de régions locales non supervisées a été largement explorée sur la base du clustering, de l'optimisation de critères globaux ou de l'interaction avec l'utilisateur. L'essor des technologies d'apprentissage profond a favorisé la classification supervisée à grande échelle, passant de la classification d'objets au niveau de

l'image à la localisation d'objets au niveau de la boîte, puis à la segmentation d'objets au niveau du pixel. Par conséquent, la segmentation d'image d'aujourd'hui est orientée objet et peut être divisée en deux branches subtiles : la première c'est la segmentation sémantique, qui attribue chaque pixel d'une image à une classe d'objets sémantique, comme le montre la figure 2-9 (c). La deuxième c'est la segmentation d'instance, qui prédit différentes étiquettes pour différentes instances d'objets comme une amélioration supplémentaire de la segmentation sémantique, comme le montre la figure 2-9(d).

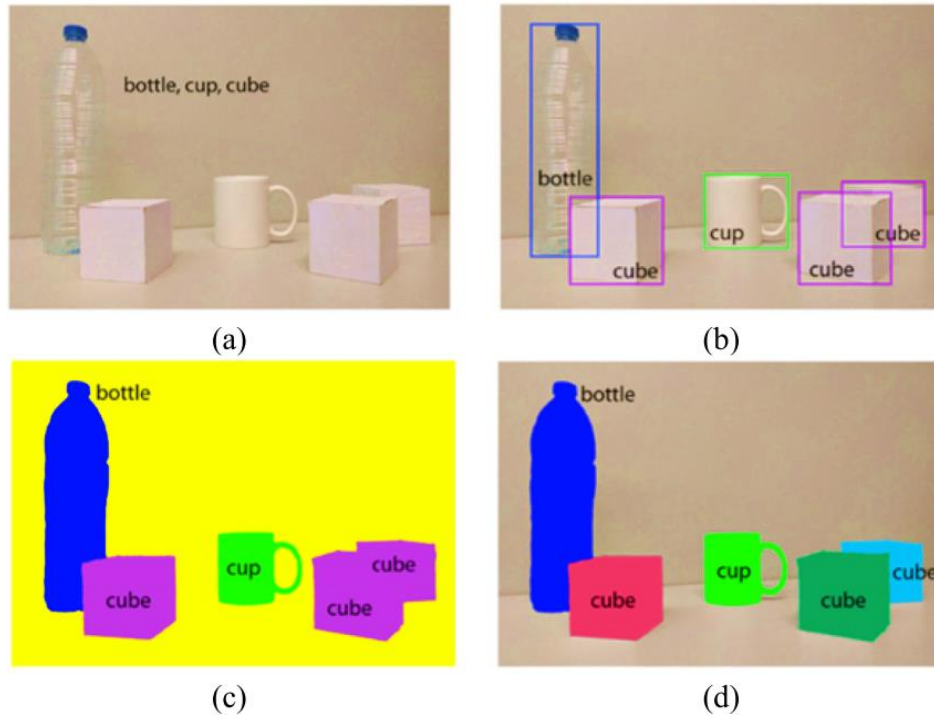


Figure 2- 9: (a) classification d'images, (b) détection d'objets, (c) segmentation sémantique et (d) segmentation d'instances

Dans le prolongement de Faster R-CNN, Mask R-CNN a ensuite été proposé pour combiner la détection d'objets et la segmentation d'instances au niveau du pixel sur la base de Faster R-CNN. En utilisant ResNet-FPN comme réseau fédérateur, Mask R-CNN a démontré la meilleure précision de détection sur MS-COCO en 2017.

4. Algorithmes de vision par ordinateur

Dans cette section, nous allons explorer et comprendre l'architecture et le fonctionnement de différents algorithmes de vision par ordinateur : Region-based CNN (R-CNN), Fast R-CNN, Faster R-CNN et Mask R-CNN.

4.1 R-CNN

L'une des principales limitations du CNN est qu'il est utilisé pour la détection d'objets pour un seul objet à la fois. En outre, CNN ne fonctionne pas bien lorsque plusieurs objets sont dans le champ visuel. R-CNN [99] permettant la classification et la détection des objets à l'aide de boîtes englobantes pour plusieurs objets présents dans une image. Au lieu d'utiliser des fenêtres coulissantes, cette méthode utilise l'algorithme de recherche sélective qui tire parti de la segmentation des objets et de la recherche exhaustive pour déterminer efficacement les propositions de régions. Cet algorithme de recherche sélective propose environ 2000 propositions de régions par image. Celles-ci sont ensuite transmises au modèle CNN. Ce modèle CNN produit ensuite un vecteur de caractéristiques (1,4096) à partir de chaque proposition de région. Ce vecteur est ensuite transmis au modèle SVM pour la classification des objets et au régresseur de la boîte de délimitation pour la localisation.

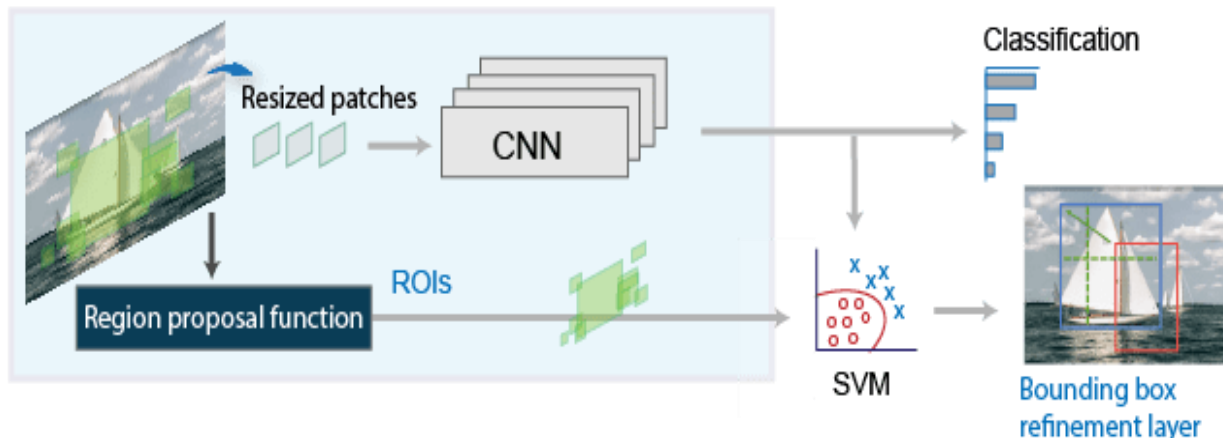


Figure 2- 10: L'architecture de R-CNN

Comme illustré sur la figure 2-10, la première étape du pipeline R-CNN est la génération de "propositions de régions" ou de régions dans une image qui pourraient appartenir à un objet particulier. R-CNN utilise l'algorithme de recherche sélective. L'algorithme de recherche sélective met l'accent sur un algorithme de segmentation basé sur le regroupement hiérarchique. Le regroupement hiérarchique commence par des régions initiales ; les régions les plus similaires sont ensuite fusionnées pour former de nouvelles régions - ce processus se poursuit jusqu'à ce que l'image entière soit représentée par une seule région. Les régions de chaque étape sont ajoutées aux propositions de régions. La similarité a été calculée en termes de similitude de couleur de texture et ainsi de suite. La deuxième étape est donc l'extraction de caractéristiques à partir des propositions de régions. Chacune des 2000 propositions de régions générées à partir de chaque

image est convertie en entrées fixes de taille 227×227 permettre leur utilisation dans le réglage fin du CNN. Après cela, chaque proposition d'objet est mise en correspondance avec l'instance de vérité avec laquelle elle a un chevauchement IoU maximum et étiquetée comme positive (pour la classe de vérité correspondante) si l'IoU est d'au moins 0,5. Les autres cases sont traitées comme la classe de fond (négative pour toutes les classes). À la fin de ce pipeline, R-CNN génère un vecteur de caractéristiques de 4096 dimensions à partir de chacune des 2000 propositions de régions pour chaque image en utilisant un réseau neuronal convolutif (CNN) [99].

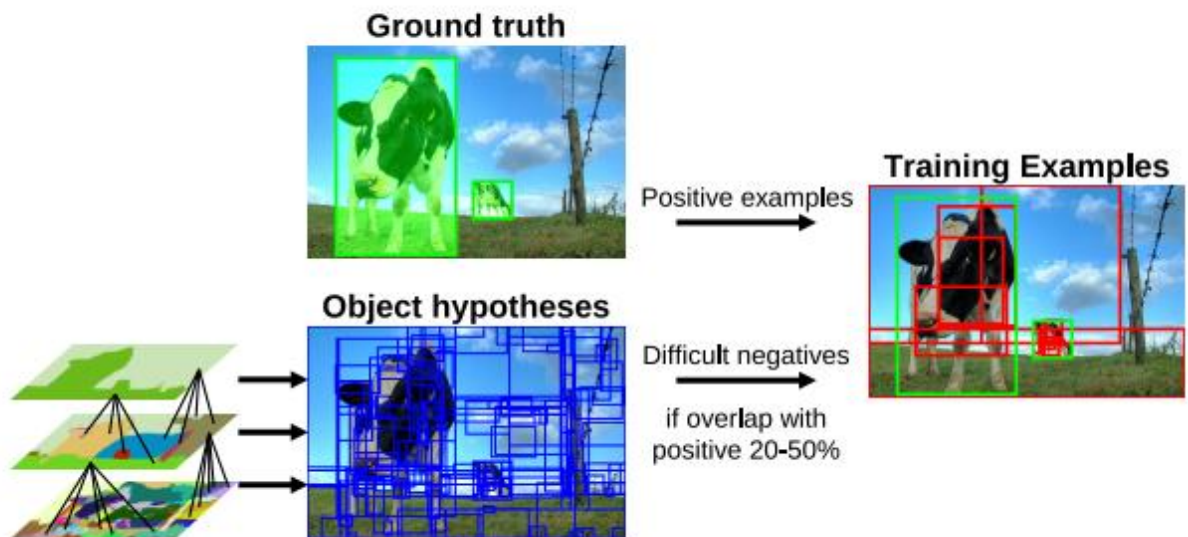


Figure 2- 11: L'extraction des caractéristiques

La figure 2-11 présente l'opération de l'extraction des caractéristiques de CNN qui agit comme un fort extracteur de caractéristiques et la sortie consiste en des caractéristiques extraites de l'image. Les caractéristiques extraites sont introduites dans un SVM pour classifier la présence de l'objet dans cette proposition de région candidate. Le SVM prend comme entrée le vecteur de caractéristiques 4096-d pour chaque proposition de région. Les caractéristiques de toutes les propositions de régions qui ont un chevauchement IoU de moins de 0,3 avec la boîte de délimitation de la vérité de base sont considérées comme négatives pour cette classe pendant l'apprentissage. Après l'entraînement du SVM, la sortie finale est un ensemble de propositions d'objets positifs pour chaque classe, à partir des caractéristiques CNN de 2000 propositions de régions (de chaque image).

En plus de prédire la présence d'un objet dans les propositions de régions, l'algorithme prédit également quatre valeurs qui sont des valeurs de décalage pour augmenter la précision de la boîte de délimitation.

Le R-CNN a également certaines limites, car chaque image doit classifier 2000 propositions de régions. Il faut donc beaucoup de temps pour entraîner le réseau. Il faut 49 secondes pour détecter les objets dans une image sur GPU. Pour stocker la carte de caractéristiques de la proposition de région, beaucoup d'espace disque est également nécessaire.

4.2 Fast R-CNN

Le même auteur de l'article sur le R-CNN a résolu certains des inconvénients du R-CNN pour construire un algorithme de détection d'objets plus rapide, appelé Fast R-CNN. Fast R-CNN consiste en un CNN (généralement pré-entraîné sur la tâche de classification ImageNet) dont la couche de Pooling finale est remplacée par une couche de "Pooling ROI" et dont la couche FC finale est remplacée par deux branches une branche de couche Softmax de $(K+1)$ catégorie et une branche de régression de boîte limite spécifique à la catégorie.

L'approche est similaire à l'algorithme R-CNN. Mais, au lieu d'alimenter le CNN avec les propositions de régions, nous alimentons le CNN avec l'image d'entrée pour générer une carte de caractéristiques convolutives. L'image entière est introduite dans le CNN dorsal et les caractéristiques de la dernière couche de convolution sont obtenues comme le montre l'architecture sur la figure 2-12. Selon le CNN dorsal utilisé, les cartes de caractéristiques de sortie sont beaucoup plus petites que la taille de l'image originale.

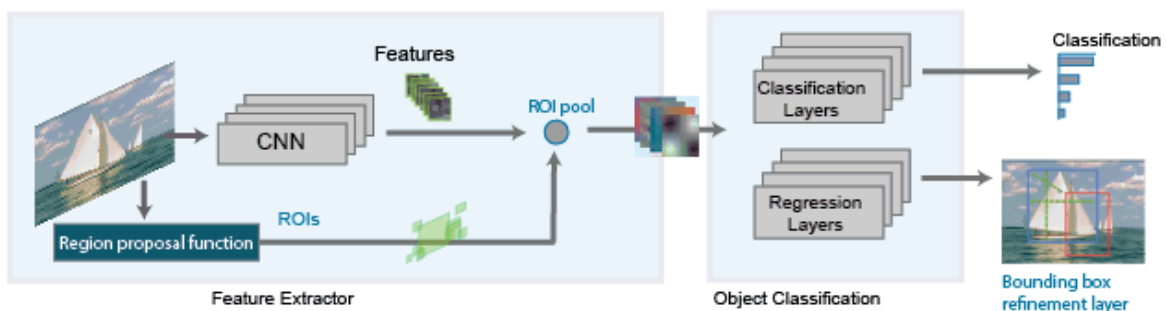


Figure 2- 12: L'architecture de Fast R-CNN

Pendant ce temps, les fenêtres de proposition d'objet sont obtenues à partir d'un algorithme de proposition de région comme la recherche sélective. Les propositions d'objets sont des régions rectangulaires sur l'image qui signifient la présence d'un objet. La partie de la carte de

caractéristiques de l'épine dorsale qui appartient à cette fenêtre est ensuite introduite dans la couche Pooling ROI.

L'obstacle majeur pour passer de la classification d'images à la détection d'objets est la taille fixe requise pour l'entrée du réseau en raison des couches entièrement connectées existantes. Dans la détection d'objets, chaque proposition aura une forme différente. Il est donc nécessaire de convertir toutes les propositions en une forme fixe, comme l'exigent les couches entièrement connectées. Le ROI Pooling fait exactement cela.

La raison pour laquelle le "Fast R-CNN" est plus rapide que le R-CNN est qu'il n'est pas nécessaire d'envoyer 2000 propositions de régions au réseau neuronal convolutif à chaque fois. Au lieu de cela, l'opération de convolution est effectuée une seule fois par image et une carte de caractéristiques est générée à partir de celle-ci [100].

4.3 Faster R-CNN

Dans la famille des R-CNN, l'évolution entre les versions s'est généralement faite en termes d'efficacité de calcul (intégration des différentes étapes d'apprentissage), de réduction du temps de test et d'amélioration des performances. Ces réseaux se composent généralement d'un ensemble de parties: (a) d'un algorithme de proposition de région pour générer des "boîtes limites" ou des emplacements d'objets possibles dans l'image; (b) d'une étape de génération de caractéristiques pour obtenir les caractéristiques de ces objets, généralement à l'aide d'un CNN; (c) d'une couche de classification pour prédire à quelle classe appartient cet objet; et d) d'une couche de régression pour préciser les coordonnées de la boîte limite de l'objet.

Le Faster R-CNN [101] a été introduit en 2015 par He et al. Après le Fast R-CNN, le goulot d'étranglement de l'architecture est la recherche sélective. Puisqu'elle doit générer 2000 propositions par image. Elle constitue une part importante du temps d'apprentissage de l'ensemble de l'architecture.

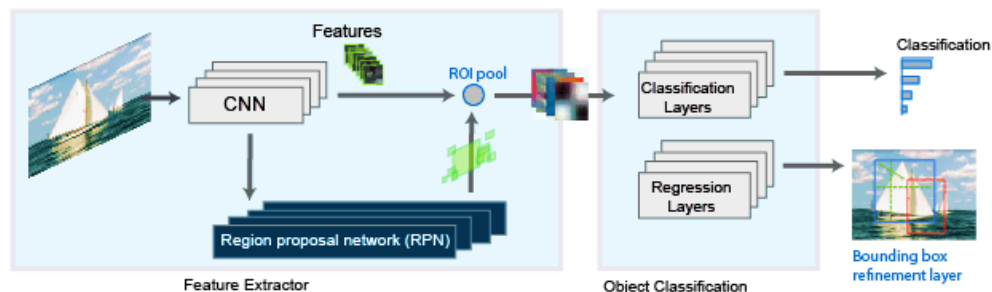


Figure 2- 13: L'architecture de Faster R-CNN

Le R-CNN et le Fast R-CNN utilisent tous deux des algorithmes de proposition de région basés sur le l'algorithme de recherche sélective qui prend environ 2 secondes par image et fonctionne sur le calcul du CPU. Comme indiqué sur la figure 2-13, le Faster R-CNN [101] résout ce problème en utilisant un autre réseau convolutif (le RPN) pour générer les propositions de régions. Cela permet non seulement de réduire le temps de proposition de région de 2 s à 10 ms par image, mais aussi de partager les couches de l'étape de proposition de région avec les étapes de détection suivantes, ce qui entraîne une amélioration globale de la représentation des caractéristiques [101]. Le terme "Faster R-CNN" fait généralement référence à un pipeline de détection qui utilise le RPN comme algorithme de proposition de région et le Fast R-CNN comme réseau de détection. Tout d'abord, dans ce réseau, nous avons fait passer l'image dans le réseau dorsal. Ce réseau dorsal génère une carte de caractéristiques de convolution. Ces cartes de caractéristiques sont ensuite transmises au réseau de proposition de région. Le réseau de proposition de région prend une carte de caractéristiques et génère les ancres (le centre de la fenêtre coulissante avec une taille et une échelle unique). Ces points d'ancrage sont ensuite transmis à la couche de classification (qui détermine s'il y a ou non un objet) et à la couche de régression (qui localise la boîte de délimitation associée à un objet) [101].

4.4 Mask R-CNN

Mask R-CNN [102] est un système de détection d'objets et de segmentation d'instances à la pointe de la technologie, qui ajoute une branche de prédiction de masque au dernier stade de Faster R-CNN, développé en Python par Facebook. Ainsi, Mask R-CNN a trois sorties, une étiquette de classe, un décalage de la boîte englobante et une troisième branche qui produit le masque de l'objet. La couche de regroupement des ROI est également remplacée par la couche d'alignement des ROI, qui est plus performante en matière de prédiction de masque qu'une couche de regroupement des ROI. Le Mask R-CNN est également divisé en deux parties, le réseau dorsal qui est responsable de l'extraction des caractéristiques (la première couche détecte les caractéristiques de bas niveau et la couche suivante les caractéristiques de plus haut niveau) et de la proposition de région et la tête du réseau qui effectue la classification, la régression et la prédiction de masque.

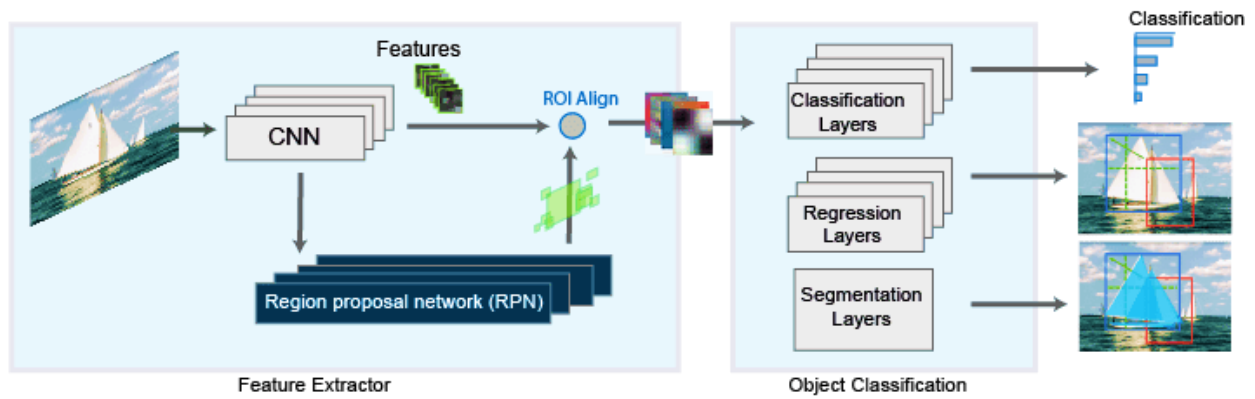


Figure 2- 14: L'architecture de Mask R-CNN

Le Mask R-CNN est divisé en deux étapes comme l'illustre la figure 2-14. Au premier niveau ou à la première étape, le cadre prend une image d'entrée, la scanne pour trouver les zones qui contiennent probablement un objet en utilisant un réseau de proposition de région (RPN). Sur la base des zones proposées lors de la première étape, le cadre prédit les classes lors de la deuxième étape, affine la boîte de délimitation et génère les masques de segmentation pour chaque objet[102].

Dans le Mask R-CNN [102], nous faisons la différence entre : l'architecture dorsale convolutive qui est composée des éléments suivants : réseau dorsal, réseau de proposition de régions et module de classification d'objets. La tête de réseau qui contient le module de régression de la boîte englobante et le module de segmentation de masque. Chaque image d'entrée est convertie en une carte de caractéristiques par le réseau dorsal qui est un réseau neuronal convolutif standard (CNN) qui extrait les caractéristiques. La carte de caractéristiques est donc utilisée comme entrée pour l'étape suivante où le réseau de proposition de région (RPN) analyse les images entières pour détecter les zones candidates qui contiennent des objets. La mise en œuvre de l'étape d'extraction des caractéristiques est basée sur la mise en œuvre originale de modèle Faster R-CNN avec ResNet-101 [103].

ResNet-101 contient 104 couches convolutionnelles au total. En outre, il se compose de 33 blocs de couches au total et 29 de ces blocs utilisent directement la sortie du bloc précédent qui est définie comme des connexions résiduelles ci-dessus, ces résidus sont utilisés comme premier opérande de l'opérateur de sommation utilisé à la fin de chaque bloc pour obtenir l'entrée des blocs suivants. Les 4 blocs restants prennent la sortie du bloc précédent et l'utilisent dans une couche de convolution avec une taille de filtre de 1×1 et un stride de 1, suivie d'une couche de normalisation par lot qui effectue une opération de normalisation et la sortie résultante est envoyée à l'opérateur

de sommation à la sortie de ce bloc [104]. La figure 2-15 présente les détails de l'architecture dorsale du Mask R-CNN.

Configurations:	
BACKBONE	resnet101
BACKBONE_STRIDES	[4, 8, 16, 32, 64]
BATCH_SIZE	1
BBOX_STD_DEV	[0.1 0.1 0.2 0.2]
COMPUTE_BACKBONE_SHAPE	None
DETECTION_MAX_INSTANCES	100
DETECTION_MIN_CONFIDENCE	0.9
DETECTION_NMS_THRESHOLD	0.3
FPN_CLASSIF_FC_LAYERS_SIZE	1024

Figure 2- 15: L'architecture dorsale du masque R-CNN

Pour la tête du réseau, le cadre Mask R-CNN étend les têtes de boîte Faster R-CNN de ResNet et FPN en ajoutant une branche de prédiction de masque entièrement convolutive [102].

Mask R-CNN utilise l'apprentissage par transfert dans l'étape de l'apprentissage, comme le principal jeu de données utilisé par Mask R-CNN est le jeu de données MS COCO qui a 80 classes et 115000 images de l'entraînement, Mask R-CNN utilise le poids préformé que le modèle a appris sur ce jeu de données avec notre propre jeu de données pour l'apprentissage de modèle [102].

5. Agriculture intelligente basée sur Deep Learning

Au cours de notre analyse documentaire, nous avons analysé de nombreux articles scientifiques (35 travaux de recherche) qui présentaient un inventaire important traitant le sujet de l'apprentissage en profondeur dans l'agriculture. Ces articles présentaient les techniques utilisées, les domaines d'utilisation, les datasets, le traitement des données, les paramétrages des modèles, les résultats, la comparaison avec d'autres, etc.

Grâce à cette analyse, nous confirmons qu'il existe plus de seize domaines dans lesquels l'apprentissage en profondeur a été utilisé dans l'agriculture, les plus répandus sont : l'identification des mauvaises herbes, la détection des insectes, la découverte des maladies des plantes, la couverture du sol, la classification des types de fruits, la reconnaissance d'espèces de fleurs. Il s'avère que la plupart de ces utilisations sont liées à l'image comme paramètre très important. La plupart des articles ciblent les cultures, le reste se répartit entre la détection des mauvaises herbes, la couverture du sol, les prévisions climatiques, l'élevage, l'irrigation, etc. La découverte des mauvaises herbes étant encore un domaine de recherche, nous en avons fait l'un des objectifs de nos recherches. La figure 2-16 montre les applications liées au deep learning dans l'agriculture.

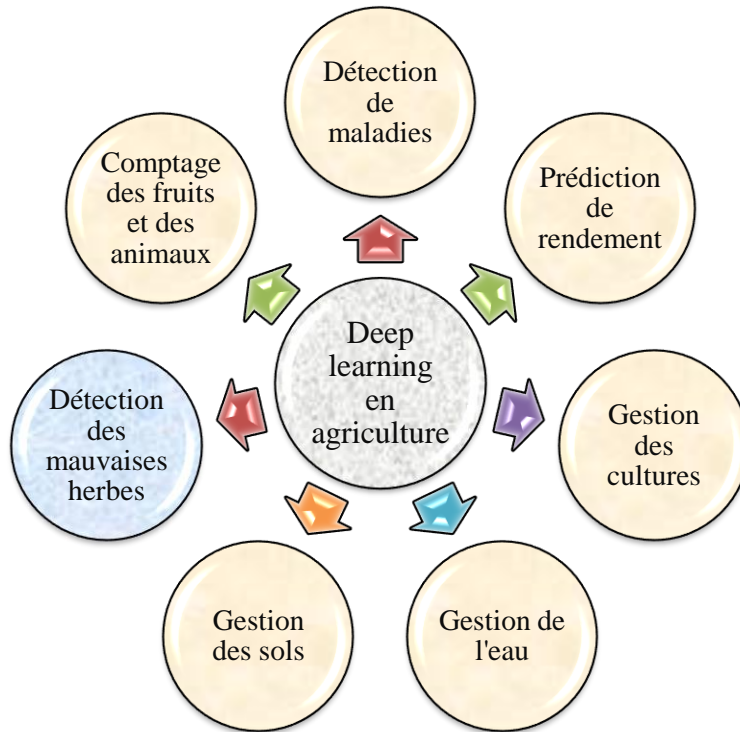


Figure 2- 16: Les applications les plus répandues du DL en agriculture

Parmi les autres données importantes qui ont été extraites de ces articles, les modèles d'apprentissage profond se sont multipliés et diversifiés dans la plantation de cultures, la figure 2-17 montre que les CNN (Convolutional Neural Networks) ont pris la plus grande part d'utilisation en agriculture avec un pourcentage de 80% et seulement 20% pour les autres techniques [77]. Cette forte exploitation de CNN dans l'agriculture en raison de ses fortes capacités de traitement d'images.




Figure 2- 17: L'utilisation des méthodes d'apprentissage en profondeur dans l'agriculture [77]

5.1 Applications de Deep Learning dans le domaine agricole

Dans cette section, nous explorons les différentes applications du deep learning en agriculture dont nous avons mentionné quelques détails dans les chapitres précédents afin de situer les apports de notre méthode au domaine dans ce contexte. Ces travaux qui seront présentés sont ceux que nous avons analysés pour comprendre l'utilisation de deep learning ainsi ses domaines d'application en agriculture. On va commencer par le domaine des plantes comme notre domaine de contribution, ensuite le domaine animalier, en va finir cette section par un tableau récapitulatif des autres domaines agricoles qui utilisent le DL.

5.1.1 Domaine des plantes

Avec la propagation du besoin de plus de production agricole, le nombre de zones cultivées s'est étendu, en parallèle divers processus d'apprentissage en profondeur ont été utilisés pour augmenter la production et faire face à divers problèmes auxquels l'agriculture est confrontée, tels que les la découverte des insectes et des maladies, ainsi l'identification des plantes nuisibles, la classification des types de plantes, la reconnaissance des fleurs de plante.

Les études scientifiques explorées, qui traitent l'apprentissage en profondeur au profit des plantes, sont divisées en recherches pour reconnaissance des types d'herbes, recherches pour l'identification des types de fleurs, d'autres pour la détection des mauvaises herbes et aussi pour découvrir les maladies des plantes. Dans ce contexte, Ning et al. [105] ont mené des recherches sur la détection des gousses et des tiges dans le soja, basée sur l'algorithme IM-SSD + ACO, la précision moyenne du modèle utilisé dans cette étude était de 7,79. Mohanty et al. [106] ont réalisé une étude sur la détection des maladies des plantes utilisant AlexNet, GoogleNet et exploitant PlantVillage comme source de données, le modèle atteint une précision de 99,35%. Un système de prédiction et classement nutritionnels des carences de la plante de tomate avec les modèles de Deep learning, Inception-ResNet V2 et AutoEncoder la Base de données collectées, par les auteurs Tran et al. [107] et les résultats sont intéressants avec une Top-3 précision de 87,273% et avec une validité moyenne de 91%. Gao et al. [108] ont proposé une méthode de classification de la maladie des plantes racines basée sur le deep learning, les résultats expérimentaux montrent que le taux de précision peut atteindre plus de 90%. D'autres chercheurs travaillent sur le même sujet, Gu et al. [109], mais cette fois, il s'agit d'un diagnostic basé sur l'image de la maladie du piment et des ravageurs utilisant l'apprentissage par transfert et l'ajustement, le modèle proposé atteint des précisions de 96,02%. Ainsi d'autres ont atteint une précision de 93,37 % pour la détection des maladies des plantes de

tomate utilisant un paradigme appelé « contrôle vers des classes cibles » à base de deep learning [110]. Une étude sur l'apprentissage automatique pour l'identification de cultivars de proposée par Zhang et al. [11], le résultat a atteint une précision de 91,88 % sur un dataset public (Oxford 102 Flowers dataset). Ghazi et al. [112] ont utilisé VGGNet affiné, AlexNet et GoogLeNet pour l'identification des plantes, ils ont utilisé LifeCLEF 2015 comme donnée de l'apprentissage, les résultats obtenus une précision de 80 % par rapport à la campagne LifeCLEF 2015, les résultats du modèle se sont améliorés de 15 %.

L'autre partie de nos recherches est liée à la détection des mauvaises herbes dans les cultures. Etienne et al. [113] ont mené une étude sur l'identification de mauvaises herbes basée sur la détection des objets utilisant YOLOv3, où un score moyen de précision (AP) de 91,48 % a été observé. Une autre étude sur la reconnaissance des mauvaises herbes à l'aide de FPN-InceptionV2 a été pilotée par Kartal [114], un pourcentage de 76,70 % a été atteint. Une recherche sur l'apprentissage profond multimodal pour la détection des mauvaises herbes dans les champs de blé, effectuée par Xu et al. [115], confirme une précision de détection globale de 89,3 %. Nous avons également mené une étude sur les mauvaises herbes dans les champs de blé au Maroc. La technique proposée basée sur YOLOv5 qui nous a donné de bons résultats. Le modèle est arrivé à une précision de 83 %. Les détails de cette étude seront présentés dans les chapitres suivants. Sur la base de ces résultats, nous proposons un système intelligent basé sur des modèles de détection d'objets, mis en œuvre sur un Raspberry, cherchant à identifier la présence d'objets pertinents (mauvaises herbes) dans une zone (culture de blé) en temps réel et classer ces objets pour l'aide à la décision, y compris pulvérisation localisée avec un herbicide choisi en fonction de la mauvaise herbe détectée. Le tableau 2-4 présente d'autres résumés d'exemples d'articles de recherche sur l'application de l'apprentissage profond à la détection des mauvaises herbes.

Tableau 2- 4. Applications de deep learning en agriculture (détection des mauvaises herbes)

Réf	[116]	[117]	[118]
Description du problème	Détection et classification des mauvaises herbes dans les cultures de soja.	Détection et classification des mauvaises herbes par analyse de bande spectrale.	Accélérez une approche DL avec FPGA pour la classification des mauvaises herbes avec 8 classes.
Données utilisées	400 images de cultures capturées par les auteurs avec un drone.	200 images hyperspectrales avec 61 bandes.	18000 images de mauvaises herbes à partir du dataset DeepWeedX.
Architecture DL	CNN	CNN	CNN

Précision globale	98%	94.72 %	90.08%
Comparaison avec d'autres méthodes Précision	SVM : 98% AdaBoost : 98.2 % Random Forest: 96 %	HoG : 74.34 %	ResNet : 95.7 %

À travers cette revue de littérature, il s'avère qu'il existe de nombreuses approches de DL utilisées pour la détection des adventices dans les cultures, nous avons identifié les lacunes de la recherche pour ce problème, par exemple, le manque de grands ensembles de données sur les cultures et les mauvaises herbes, une précision de classification acceptable pour n'importe quel problème, le manque de modèles généralisés pour détecter différentes plantes cultivées et espèces de mauvaises herbes. Les chercheurs et ingénieurs sont responsables de l'apprentissage du modèle de réseau de neurones qui identifie les cultures et les mauvaises herbes. C'est un problème difficile, car de nombreuses mauvaises herbes ressemblent à des cultures. Des agronomes professionnels et des désherbants forment des systèmes d'étiquetage et d'annotation pour étiqueter correctement les images.

5.1.2 Domaine animalier

Comme l'apprentissage en profondeur a été utilisé pour les plantes et les cultures, il a également été utilisé dans le domaine des animaux, pour les identifier, les compter, comprendre leur comportement, etc. Le chercheur Santana et al. [119] ont conçu un système de vision par ordinateur pour la classification et la segmentation des superpixels des moutons, ce système est à base de VGG16, ResNet152V2, InceptionV3 et DenseNet201, il a atteint une précision de 0,928 et 0,928 pour F-score. Sarwar et al. [120] ont réalisé une étude de cas pour la détection le compte des moutons utilisant la vidéo du drone, ils ont formé un modèle de réseau neuronal profond basé sur R-CNN, ils ont obtenu une précision de 100 %. Neethirajan [121] a développé un système de suivi automatisé pour l'évaluation de la volaille d'élevage, l'idée de ce système est basée sur un suivi permanent utilisant des caméras liées à des systèmes spécialisés d'IA peut analyser correctement les troupeaux pour des problèmes de santé et ça va améliorer le taux de survie et la qualité des produits de la volaille d'élevage. D'autres travaux Jwade et al. [122] ont proposé un modèle basé sur les réseaux de neurones pour reconnaître et prédire les types des animaux dans un environnement, ils ont atteint une précision de 95,8 %. Toujours dans le domaine des animaux, le deep learning est utilisé souvent pour la segmentation des bovins et extraction des contours et là on a une recherche dont laquelle Qiao et al. [123] ont utilisé Mask R-CNN amélioré dans un environnement réel, le modèle a atteint une précision mPA de 0,92.

De nombreuses recherches ont utilisé l'apprentissage en profondeur dans l'élevage et l'exploitation des porcs. Par exemple, le système automatique réalisé par Wtuke et al. [124] pour la détection et le suivi des porcs, ce framework est basé sur CNN pour détecter l'emplacement des porcs dans une vidéo et suivre leurs trajectoires de mouvement sur une période de temps à l'aide d'un algorithme de filtre de Kalman (KF). Toujours pour le même objectif (suivi des porcs), un autre modèle de deep learning est conçu par Bhujel et al. [125], l'opération est basée sur les activités physico-temporelles à différentes concentrations de gaz à effet de serre, le système proposé est basé sur YOLOv4 et Faster R-CNN, il a atteint une précision mAP de 98,67%.

5.1.3 Autres domaines

L'agriculture est un domaine concerné par les innovations technologiques pour favoriser la production et garantir la sécurité alimentaire. De nombreuses recherches dans ce domaine ont été publiées et sont encore publiées, le deep learning est au centre de ces développements technologiques qui ont révolutionné ce domaine. Ces études ont été menées dans divers domaines de l'agriculture, nous avons mentionné précédemment le domaine des plantes et le domaine animal, d'autres domaines sont présentés dans le tableau 2-5:

Tableau 2- 5. Applications de deep learning pour un groupe de problèmes agricoles

Réf.	Problème de Recherche	Modèle proposé	Source de données	Résultats
[126]	Occupation du sol.	Ensemble de CNN.	Des images de satellite Landsat-8 et Sentinel-1A RS.	Des précisions supérieures à 85% pour toutes les principales cultures (blé, maïs, tournesol, soja et betterave à sucre).
[127]	L'occupation des sols et des couvertures terrestres.	Une architecture CNN à deux branches (MultiResoLCC).	Des données fournies par les capteurs VHSR .	Les résultats de précision, de F-Measure et de Kappa obtenus sont : 71, 98, 71,73 et 0,6797.
[128]	Gouvernance de l'eau en Irrigation.	Les réseaux de neurones convolutionnels Bi-Stream profonds.	Données recueillies par télédétection	La précision moyenne était de 86,23 % et la méthode a obtenu une amélioration de 15 % à 17 % par rapport aux méthodes de référence.
[129]	La détection automatique du stress hydrique des pêcheurs cultivés en pot.	HortNet417v1 avec 417 couches.	50 632 images augmentées.	HortNet417v1 a une précision d'apprentissage de 90,77 %, une validation croisée de 90,52 % et une précision de test de 93,00 % sans aucun problème de surajustement.
[130]	Prévision de l'évapotranspiration sous	Réseaux de neurones récurrents	Données recueillies sur deux sites aux climats différents : Cypress	Les modèles ont généralement fourni des résultats plus précis.

	différents climats pour la gestion des ressources en eau.	(RNN).	Swamp, sud de la Floride et Kobeh Valley, centre du Nevada.	
[131]	Estimation des taux d'utilisation de l'eau sur la base de variables hydrométéorologiques.	Réseau de croyances profondes (DBN), (deep belief network).	Variables météorologiques accumulées pour différentes durées.	Les résultats ont montré de meilleures performances.
[132]	Détection des fruits en temps réel dans l'arbre.	CNN	Plus de 100 images de pommiers et de poiriers ont été prises manuellement.	L'architecture a montré une précision de plus de 90% de pour la détection des fruits.
[133]	La reconnaissance des fruits.	EfficientNet	Jeu de données public (Kaggle).	La précision du modèle proposé était de 95,67 %.
[134]	Prédire les tendances de la production céréalière.	CNN	Statistique de la production céréalière.	96,7 % de précision.
[135]	Prédire l'humidité du sol.	CNN and SVM	Données météorologiques multi-entrées (multi-input).	Une précision accrue à 89%.
[136]	Prédiction de l'humidité relative dans un bassin.	Réseaux de neurones artificiels (ANN) et programmation de l'expression génétique (GEP).	Les variations temporelles des variables météorologiques de la station de (à partir des données collectées de 1995-2009).	Les modèles peuvent prédire l'humidité relative de manière fiable (RMSE = 10,7 %, MAE = 7,6 % et R2 = 0,73) pendant l'entraînement.
[137]	Classification et détection des insectes dans les grandes cultures.	ANN, SVM, KNN et NB	L'ensemble de données Wang pour 1 359 images d'insectes et l'ensemble de données Xie pour 6 892 images d'insectes comprennent des images de test de fourni augmentées.	Les résultats ont montré une précision de classification de 79,9 % et 71,8 % pour 5 et 9 classes d'insectes.
[138]	Prévision des basses températures pour l'agriculture.	Réseaux de neurones récurrents (RNN)	Données réelles obtenues à partir du système IoT déployé.	Les résultats moyens obtenus après l'exécution de l'expérience sont : RMSE = 0,77, MAE = 0,41.

5.2 Répartition technique

Les trente-cinq articles que nous avons exploités dans cette étude nous apportent des détails techniques qui diffèrent selon le problème traité. Il y a ceux qui s'appuient sur des modèles d'apprentissage en profondeur basés sur CCN, qui est le plus utilisé, d'autres s'appuient sur des améliorations de AlexNet et VGG pour obtenir de meilleurs résultats, puis un autre groupe utilise

les CNN améliorés. Le tableau 2-2 classe les articles en groupes selon les détails techniques utilisés.

Tableau 2- 6. Classement des articles analysés selon les techniques DL

Techniques DL	Nombre d'articles
CNN	15
RNN	4
Mask R-CNN et Faster-CNN	3
YOLO	3
Inception	3
Autres	3
AlexNet	2
ResNet	2
VGG	2
EfficientNet	1
DBN	1
DenseNet	1

Comme il est clair ci-dessus, le CNN avec ses différents types et de ses différentes architectures a été beaucoup utilisé dans le domaine de l'agriculture. Il existe des articles qui utilisent plus d'un modèle, parfois ils sont combinés entre eux ou améliorés, d'autres ont ajouté un modèle de classification au dernier niveau, comme : les machines vectorielles évolutives (SVM), la régression logistique, ou la régression linéaire, etc.

En ce qui concerne les frameworks, Caffe étant le plus populaire, suivi de TensorFlow et deeplearning4j. D'autres travaux de recherche ont développé leur propre framework, tandis que certains auteurs ont décidé de construire leurs propres modèles à partir de Caffe, Keras/Theano, Keras/TensorFlow et MatConvNet.

La figure 2-18 présente les scores des frameworks selon un ensemble de critères tels que : la courbe d'apprentissage, la vitesse de développement, la taille et passion de la communauté, le nombre d'articles mis en œuvre dans le framework, la probabilité de croissance et de stabilité à long terme, écosystème d'outils. L'utilisation de TensorFlow et Keras est la plus dominante dans l'industrie et dans la communauté de la science des données [139][140]. Pytorch s'est également classé parmi les premiers rangs ces dernières années [141].

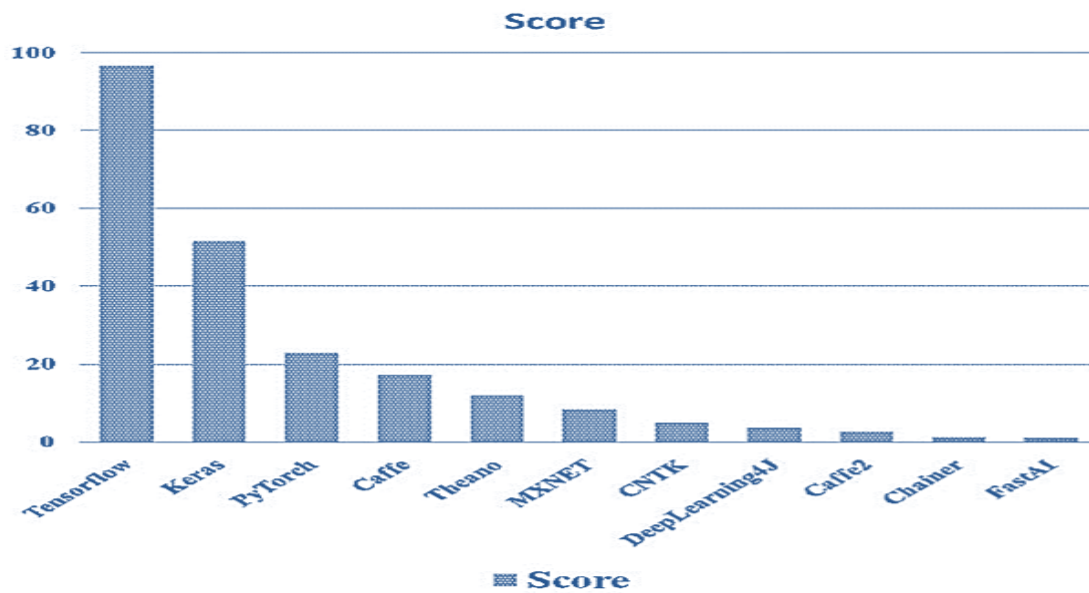


Figure 2- 18: L'ordre des frameworks de deep learning (2020) [139]

5.3 Sources de données et métadonnées

L'ensemble de données est considéré comme le carburant qui exécute tout modèle d'apprentissage en profondeur. Les sources de données utilisées dans les articles de l'étude varient d'un article à l'autre, où un groupe de chercheurs travaille sur des projets avec datasets personnalisés en fonction de leurs propres besoins et selon le problème étudié. Ils créent leurs propres datasets en suivant un ensemble d'étapes et en utilisant un ensemble de méthodes. Un autre groupe de scientifiques a utilisé des datasets publics, ce type de dataset ont été produits par des scientifiques lors d'expériences ou lors de compétitions dans un domaine spécifique et ils l'ont présenté au public pour une utilisation dans des projets de science des données. Les images contenues dans ce jeu de données sont pour la plupart annotées.

La plupart des études ont divisé leurs données entre celles d'apprentissage et celles de test/validation, d'autres études ont utilisé la méthode de cross-validation " re-sampling " (ré-échantillonnage) pour évaluer le modèle même avec des données limitées. Une approche générale utilisée par de nombreux articles évalués consiste à commencer avec une perte d'apprentissage élevée et à la réduire au fur et à mesure de l'apprentissage. Nous notons que la perte d'apprentissage dépend fortement de l'architecture du réseau et de la taille du dataset.

Les datasets d'image publique, basés sur des tâches d'agriculture de précision sont classés selon le problème traité, à savoir le contrôle des mauvaises herbes, la détection des fruits et autres, comme résumé dans le tableau 2-7.

Tableau 2- 7. Datasets d'images publiques dédiées au DL pour l'agriculture

Nom du dataset	Application	Images	URL
DeepWeeds Public	Classification des mauvaises herbes	17509	https://github.com/AlexOlsen/DeepWeeds
Weed-AI Public	Classification des mauvaises herbes	18345	https://weed-ai.sydney.edu.au/explore
DeepSeedling	Détection et comptage des semis	5743	https://github.com/UGA-BSAIL/deepseedling
CottonWeeds	Classification des mauvaises herbes	5187	https://www.kaggle.com/yuzhenlu/cottonweedid15
Agri_data	Culture et mauvaises herbes	2601	https://www.kaggle.com/ravirajsinh45/crop-and-weed-detection-data-with-bounding-boxes
Potato-and-weeds	Pomme de terre et mauvaises herbes	18600	https://www.kaggle.com/jchrysanthemum/potato-and-weeds
Fruits 360	Reconnaissance de fruits et légumes	0380	https://www.kaggle.com/moltean/fruits
Fruits_and_Vegetables_Dataset	Reconnaissance de fruits et légumes	3825	https://www.kaggle.com/kritikseth/fruit-and-vegetable-image-recognition
Deep Fruit	Reconnaissance des fruits	10,000	https://doi.org/10.21227/x46j-sk98
Agriculture_crop	Images de cultures de blé, de riz (Paddy), de canne à sucre, de jute, de maïs (Maïs)	1107	https://www.kaggle.com/aman2000jaiswal/agriculture-crop-images
AgricultureDa	Maladie de la pomme de terre	2152	https://www.kaggle.com/sohelranaccselab/agriculture-dataset
PlantDoc-Dataset	Maladies des plantes	2,598	https://github.com/pratikayal/PlantDoc-Dataset
Plant-Disease	Classification des maladies des plantes	61,486	https://github.com/DhruvMakwana/Plant-Disease-Classification
Apple Trees	Élagage des arbres	Non spécifié	https://engineering.purdue.edu/RVL/CVP_RW_Dataset/

6. Conclusion

Le développement technologique des processeurs, des cartes vidéo, des composants de stockage ainsi que la collecte massive d'informations qui a lieu à tout moment rendent le domaine de l'apprentissage en profondeur beaucoup plus attrayant et pertinent pour le domaine agricole. Si par le passé nous avons l'habitude de voir le domaine du deep learning très limité, aujourd'hui il est particulièrement large et l'attention qui l'entoure est plus grande que jamais. Sa capacité peut être utilisée en agriculture, notamment dans le domaine de la détection des mauvaises herbes. Dans

ce chapitre, nous avons étudié le développement des efforts de travail basés sur les différentes technologies notamment les réseaux neurones profonds (deep learning) dans le domaine de l'agriculture au cours des dernières années. Nous avons analysé un ensemble de travaux sur les applications du deep learning et les détails techniques de leur mise en œuvre. Chacune des études a été envisagée en comparaison avec les techniques existantes. Pour cela nous avons présenté des études et benchmarks de différentes approches, techniques et algorithmes de l'agriculture digitale. Il a été donc constaté que le deep learning et plus précisément le CNN (Réseau neuronal convolutif) est nettement meilleur en termes de performances que les autres approches, il convient également à notre problème lié à la découverte des mauvaises herbes du fait qu'il peut être bien utilisé en photos et vidéos et en temps réel. Le chapitre suivant marque le début de nos contributions scientifiques, où nous appliquerons ces idées que nous avons tirées de la revue de la littérature à la découverte des mauvaises herbes.

CHAPITRE

III

**CHAPITRE III : ENTRAÎNEMENT DE QUELQUES
MODÈLES DE DL OPEN SOURCE AU PROFIT DE
LA DÉTECTION DES MAUVAISES HERBES**

1. Introduction

Le monde est confronté à de nombreux défis qui menacent sa sécurité alimentaire, ces défis, comme nous l'avons indiqué dans les parties précédentes, sont humains, certains sont naturels, liés au climat et à la nature [142]. Par conséquent, la technologie doit être utilisée pour comprendre, observer et analyser en permanence divers phénomènes liés à l'agriculture. Ces processus liés aux systèmes agricoles aideront à comprendre le contexte et la situation spatiale pour améliorer les tâches et prendre la bonne décision au bon moment [143]. Nous avons choisi d'appliquer ces techniques à la détection des mauvaises herbes, en vue de concrétiser la notion d'agriculture numérique à travers le processus et la chaîne de gestion des plantes comme l'un des nombreux processus à étudier dans cette transformation digitale. L'identification et la découverte des types cultures et de plantes, les analyser et les classer, nécessite deux étapes. La première étape est liée à la collecte et l'acquisition d'images. La deuxième étape est liée à l'analyse et traitement, chaque étape nécessite des techniques multiples et particulières. Parmi les techniques largement utilisées pour acquérir des images du domaine agricole, il existe des techniques qui dépendent des satellites qui effectuent un levé complet sur une grande zone spécifique [144], on trouve également les drones qui sont largement utilisés pour l'imagerie des champs et peuvent être connectés à un serveur pour analyser des images [145], ainsi que des radars imageurs comme (SAR) [146]. Ensuite, l'imagerie thermique est aussi l'une des techniques les plus importantes utilisées à cet égard [147]. En ce qui concerne la deuxième étape d'analyse, d'identification et classification des images, il existe un ensemble de techniques qui diffèrent selon la différence d'objectif. Nous trouvons d'abord le machine learning qui a envahi divers domaines dont l'agriculture est l'un d'entre eux, nous mentionnons ses algorithmes les plus utilisés tels que CNN, RNN, K-means, SVM, k-NN, ... [148]. On retrouve également les techniques de la transformée orthogonale en ondelettes comme l'un des algorithmes utilisés pour analyser et filtrer les images [149]. Le système polarimétrique pour l'analyse d'images est également l'une des techniques utilisées dans le domaine de la recherche scientifique qui est utilisée pour analyser les images et déterminer ses différents détails [150]. Il existe également l'analyse de télédétection, très utilisée dans le domaine agricole qui dépend de la technique de NDVI comme indice de végétation [151]. Enfin, l'analyse de régression pour faire des prédictions [152].

Parmi toutes les techniques évoquées, nous avons retenu le deep learning et son utilisation en agriculture. Ce choix découle de plusieurs critères dont certains ont été évoqués dans les chapitres précédents, le DL peut être considéré comme l'un des sous-domaines de l'intelligence artificielle,

DL concerne des réseaux de neurones organisés sous plusieurs couches ce qui le rend plus profond donc l'apprentissage se fait à plusieurs niveaux commençant de bas niveau au niveau plus haut. Alors les données passent de plusieurs transformations de la couche d'entrée jusqu'à la couche de sortie pour donner une capacité d'apprentissage plus grande. Deep learning ayant été appliqué avec succès dans divers domaines, il a récemment fait son entrée dans le domaine de l'agriculture [153]. Deep learning en agriculture est une technique récente, moderne et prometteuse dont la popularité ne cesse de croître, tandis que les progrès et les applications de l'apprentissage profond dans d'autres domaines indiquent son grand potentiel. C'est ce qui nous a poussés à le choisir dans nos recherches, également ce choix est confirmé par l'analyse que nous avons menée sur un grand nombre d'articles scientifiques cités dans les chapitres 1 et 2. Ce chapitre présente une étude comparative dans laquelle nous avons utilisé des modèles de vision par ordinateur open source préconfigurés pour la détection d'objets : Detectron2, EfficientDet, YOLO et Faster R-CNN. En effet, nous avons entraîné ces modèles sur notre dataset dédié à la reconnaissance des mauvaises herbes, afin d'obtenir la performance de chacun d'eux pour les comparer entre eux. Cette étude nous a montré que ces modèles ont de bons résultats d'apprentissage sur notre jeu de données, ce qui signifie qu'ils peuvent être utilisés dans le domaine de la détection des mauvaises herbes, ce qui nous permettra de les détecter en temps réel à l'aide d'un système intelligent que nous avons proposé. Cette contribution axée essentiellement sur l'utilisation des modèles de détection d'objets et utilisant nos propres données pour la détection des mauvaises herbes dans les champs de blé a fait objet d'une publication indexée Scopus. [154].

2. Hardware & Software utilisés

Dans cette section, nous définirons les méthodes, les logiciels, le matériel et les bibliothèques utilisés dans cette expérience, en passant par l'ensemble de données nécessaire à l'entraînement de nos modèles.

2.1 Tensorflow

En novembre 2015, Google a développé un nouveau framework de programmation (framework) pour le calcul numérique, appelé TensorFlow et l'a rendu open source. Ce framework est destiné notamment aux technologies de machine Learning et d'intelligence artificielle, dont s'inspire sa nomination « Tensor ». Les tenseurs sont des tables de données multidimensionnelles qui gèrent les opérations courantes sur les réseaux de neurones. C'est une Matrice. Gmail, Google

Photos et la reconnaissance vocale peuvent être utilisés comme illustration de l'application TensorFlow.

2.2 Keras

Une bibliothèque très intuitive de deep learning en python, ou ce que François Chollet appelait, en 2017, Keras. Cette API de réseaux de neurones de haut niveau vous permet de créer et de former des modèles d'apprentissage en profondeur. Ainsi, il est utilisé dans le prototypage rapide, la recherche avancée et la mise en production. Keras a pour objectif de passer de l'idée au résultat en peu de temps, dans le cadre du projet ONEIROS (Open-ended Neuro-Electronic Intelligent Robot Operating System), Système d'Exploitation de Robot Intelligent Neuro-Electronique à durée indéterminée. Cependant, comme l'a expliqué son fondateur, Keras est conçu comme une interface qui présente un ensemble d'abstractions de niveau supérieur et plus intuitif qui facilite la configuration de réseaux de neurones indépendants de la bibliothèque informatique principale.

2.3 Python

Le langage de programmation Python est largement utilisé dans l'apprentissage en profondeur. Son code n'a pas besoin d'être compilé pour fonctionner. C'est un langage de haut niveau interprété et orienté, permettant une réduction raisonnable du coût de maintenance des codes et en encourageant la modalité et la réutilisabilité. Les librairies Pythons sont gratuites pour la majorité des plateformes. Nous en avons utilisé la dernière version dans cette expérience, ainsi que dans d'autres expériences.

2.4 Apprentissage par transfert

Dans le domaine de l'apprentissage en profondeur, nous sommes tenus de donner des prédictions sur des entrées souvent très compliquées, telles que des images, des vidéos, des extraits sonores, etc. En général, quand on veut donner une prédiction, on peut le faire de l'une des 2 manières suivantes : Construire un modèle à partir de zéro ou l'utilisation d'un modèle existant et formé pour utiliser ses poids. (Apprentissage par transfert). Il existe plusieurs modèles qui peuvent nous aider à effectuer un apprentissage par transfert ou à affiner de manière efficace(fine-tuning). Par exemple, en vision par ordinateur, les réseaux de neurones tentent généralement d'identifier les bords dans leurs premières couches, les formes dans leurs couches intermédiaires et certaines de nos caractéristiques spécifiques à la mission dans les couches ultérieures. Avec le transfert

d'apprentissage, nous pouvons utiliser les premières et moyennes couches et recycler uniquement les dernières couches. Cela nous aide à exploiter les données qui y sont étiquetées par le maître du modèle initialement.

Les principaux avantages sont le gain de temps lors de l'entraînement, le réseau de neurones fonctionnera mieux dans la plupart des cas, ainsi nous n'aurons pas besoin de beaucoup de données. Habituellement, nous avons besoin de beaucoup de données pour former un réseau de neurones à partir de zéro, mais nous n'avons pas toujours accès à suffisamment de données. C'est là que le transfert d'apprentissage entre en jeu. Nous pouvons construire un modèle stable avec une quantité relativement faible de données à entraîner, puisque le modèle est déjà pré-entraîné. Par conséquent, beaucoup de temps de l'entraînement peut être économisé, ce qui est très important car l'entraînement d'un réseau de neurones profond à partir de zéro peut parfois prendre des jours, voire des semaines pour une tâche complexe.

2.5 Configuration matérielle

Une implémentation efficace d'un modèle de détection d'objets sera valide selon des conditions matérielles précises. Pour notre cas, nous avons utilisé un pc portable HP i7 CPU 2.40 GHZ, avec carte graphique Nvidia GeForce GT525M, d'une taille de 8 Go concernant la RAM et un disque dur de taille 500Go.

3. Étude comparative des modèles de détection d'objets open source

L'approche proposée dans ce travail pour la détection des mauvaises herbes est basée sur les idées extraites des articles analysés dans le chapitre précédent. La détection des mauvaises herbes et des cultures a été expérimentée avec quatre récents modèles de vision par ordinateur open source préconfigurés pour la détection d'objets : Detectron2, EfficientDet, YOLO et Faster R-CNN. La comparaison des performances des modèles de détection de mauvaises herbes est exécutée sur la plate-forme Open CV et Keras en utilisant le langage python. Nous exécutons ces modèles sur des images collectées directement sur le terrain, puis nous les comparons en termes de résultats obtenus.

3.1 Méthodes de détection d'objets basées sur le Deep Learning

Pour notre étude, nous allons exploiter la puissance de nos modèles grâce aux méthodes d'apprentissage par transfert, qui permettent d'utiliser l'apprentissage acquis sur un problème général de classification pour le réappliquer à un problème particulier [155]. Des équipes de

recherche spécialisées dans l'amélioration des CNN fournissent ces modèles. Ils publient leurs innovations techniques, ainsi que le détail des réseaux entraînés sur des bases de données de référence. Par exemple, l'ensemble de test-dev COCO, ImageNet challenge (ILSVRC), peut organiser les détecteurs d'objets en deux catégories principales ; Les détecteurs à deux étages, tels que Faster R-CNN, ont une étape de proposition de région d'intérêt et une autre classification finale et une régression de boîte englobante (Bounding-Box) des objets prenant ces régions en entrée. Les détecteurs à un étage tels que YOLO, EfficientDet, Detectron2[156] considèrent la détection d'objets comme un simple problème de régression apprenant les probabilités de classe et les coordonnées de la boîte englobante à partir des images d'entrée.

3.2 Argumentaire

Le monde de l'apprentissage automatique et de l'apprentissage en profondeur regorge de découvertes quotidiennes. Il existe des dizaines de modèles qui ont été produits dans des compétitions scientifiques ou dans des circonstances particulières. Tout cela nous a produit de nombreux modèles de classification et de détection des objets qui peuvent être adoptés pour découvrir les mauvaises herbes en temps réel, nous avons choisi ces quatre modèles pour plusieurs raisons. Les raisons du choix de ces modèles peuvent être résumées comme suit :

- La première raison est que ces modèles sont open source et leurs créateurs ont encouragé la communauté scientifique à les utiliser dans tous les domaines possibles.
- La deuxième raison est qu'il s'agit des derniers modèles de détection d'objets, le plus ancien d'entre eux n'a pas plus de 10 ans et le plus récent n'a pas plus de trois ans.
- La troisième raison est qu'ils ont été beaucoup utilisés dans des domaines comme la médecine et ont montré de bons résultats et n'ont jamais été utilisés dans le domaine de la détection des mauvaises herbes, l'objet de nos recherches.
- La quatrième raison est que ces modèles ont été préalablement pré-entraînés sur de grands ensembles de données et que leurs poids sont disponibles en téléchargement, ce qui nous permet d'exploiter la puissance de l'apprentissage par transfert (Transfer Learning).
- La dernière raison est les recommandations que nous avons glanées dans certains articles récents que nous avons examinés dans la phase de l'état de l'art et que nous avons considérés comme le point de départ de l'idée.

3.3 Architectures

Ces modèles ont des architectures à un étage ou à deux étages (one stage, two stages). Le détecteur à deux étages trouve d'abord les cibles potentielles et leurs emplacements, puis (dans la deuxième étape) classe ces cibles potentielles. La détection d'objet en une étape déduit conjointement la probabilité de position et de catégorie dans un cadre. Tout ça plus les deux parties principales : c'est l'épine dorsale (Backbone) et le cou (Neck). La première sert à extraire les caractéristiques de l'image, quant à la seconde, combine ces caractéristiques extraites pour faciliter leurs exploitations. La figure 3-1 montre la structure de ces modèles de détections d'objets.

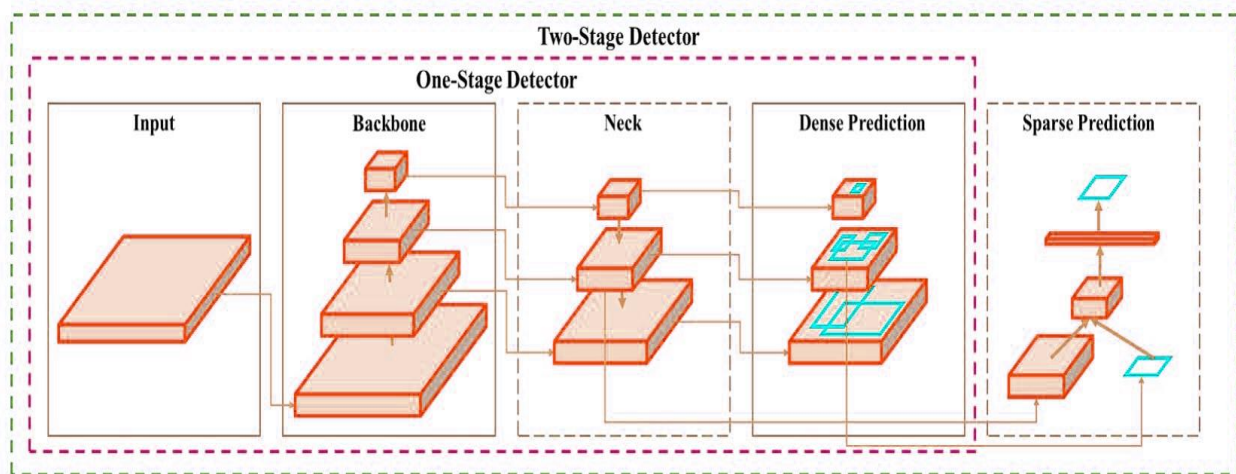


Figure 3- 1: Architecture actuelle d'un réseau de détection d'objets

3.3.1 EfficientDet

EfficientDet est une nouvelle version d'EfficientNet, c'est un modèle de détection d'objets en temps réel via un réseau personnalisé de détection et de classification. Il est plus petit, pesant 17 Mo. Il s'agit d'un modèle de réseau neuronal open source pour la tâche de vision par ordinateur de détection d'images. Cependant, il est publié initialement dans les plateformes TensorFlow et Keras, puis dans Pytorch. Les versions d'EfficientDet varient d'EfficientDet B0 à B7[157], la dernière version d'EfficientDet-D7 atteint 55,1 de précision [156].

3.3.2 Faster R-CNN

En 2014, Ross Girshick et al. [158] ont inventé une méthode de détection d'objets nommée R-CNN et améliorée avec un Faster R-CNN. C'est une méthode plus précise. Il s'agit d'un détecteur d'objets d'apprentissage en profondeur en deux étapes, à savoir :

- Identification des régions d'intérêt
- Transfert à un réseau de neurones convolutifs

La classification est effectuée par la transmission des cartes de caractéristiques produites à une machine à vecteurs de support SVM, ainsi, le calcul de la régression entre les boîtes englobantes prédites et les boîtes englobantes réelles. Faster R-CNN a un AP entre 34,9 et 36,8 sur test-dev coco [159].

3.3.3 YOLOv5

Yolo est un acronyme désignant l'expression anglaise « You Only Look Once » [160]. C'est un système adressé pour détecter des objets en temps réel à partir des images à 30 fps. Il a eu un AP amélioré (49.2 à 50.1) sur test-dev coco. Yolov5 est une continuation des versions récentes de la série YOLO. Il est plus petit et généralement plus confortable à utiliser à l'entraînement. Changer son architecture et l'exporter vers de nombreux environnements de déploiement est tout aussi simple. Cette série, publiée par Glenn Jocher le 9 juin 2020, est implémentée dans PyTorch [160].

3.3.4 Detectron2

La détection de points clés, la détection d'objets et la segmentation sémantique font partie du domaine d'intérêt prioritaire de Detectron2. Il s'agit d'un système écrit en Pytorch et contient des versions améliorées de R47-CNN, Mask R-CNN, Retinanet et Denspose. De même, il prend en charge la mise en œuvre et l'évaluation rapides de nouvelles recherches sur la vision par ordinateur, c'est pourquoi il a été inventé par Facebook AI Research (FAIR). Son AP peut atteindre 64,31 sur COCO test-dev [161].

Ci-dessous, nous illustrons les résultats des quatre modèles sur COCO test-dev en termes de précision moyenne (AP) choisie comme métrique d'évaluation principale, qui fait la moyenne de l'AP sur IoU seuils de 0,5 à 0,95 avec un intervalle de 0,05. Les données illustrées sur les graphiques de la figure 3-2 représentent la valeur de précision la plus élevée et la plus faible pour chaque version de chaque modèle.

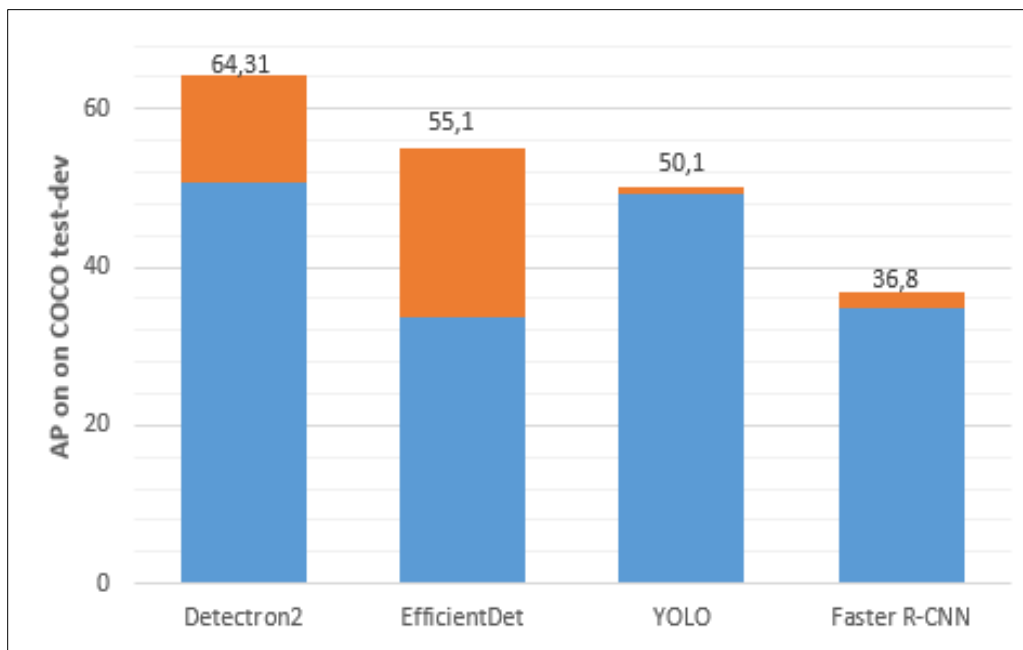


Figure 3- 2: Comparaison de précision sur COCO test-dev

La préparation et la configuration de l'ensemble de données parmi les phases les plus importantes du processus de détection d'objets. L'ensemble de données joue un rôle important dans la recherche scientifique, c'est l'un des facteurs les plus importants pour améliorer l'apprentissage en profondeur [162]. Malheureusement, les données sont encore difficiles et plus coûteuses à générer et à annoter. Un ensemble d'opérations, résumées dans la figure 3-3 ci-dessous, sont nécessaires à la préparation du jeu de données, nous les détaillerons dans cette section.

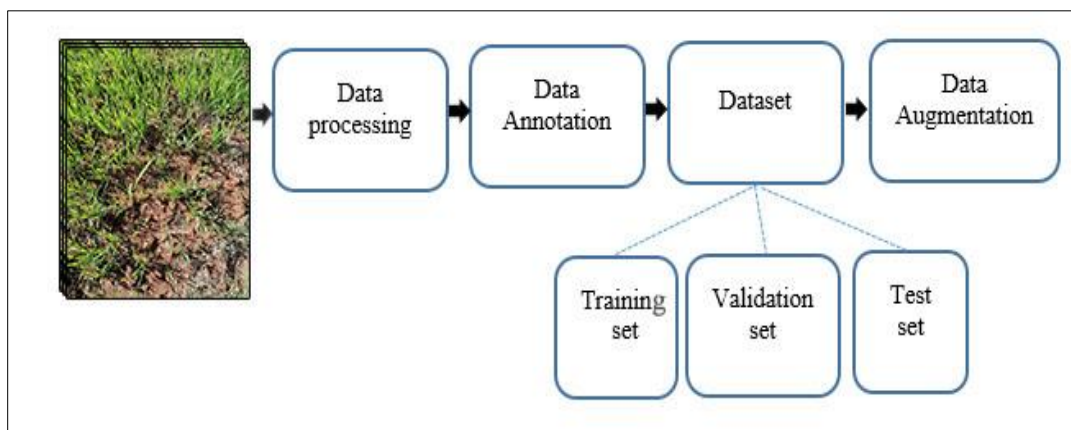


Figure 3- 3: Préparation du jeu de données

Une expérience a été faite à cet égard dans la région de Béni Mellal-Khenifra au Maroc, connue pour son climat tempéré. Il s'agit de collecter des images réelles de deux types de mauvaises herbes. Le premier est le « Phalaris Paradoxa » le second est le « Convolvulus » (figure 3-4, 3-5), ces deux types d'herbes font deux classes différentes. Pour cette expérience, un appareil photo professionnel Nikon 7000 est utilisé pour capturer 2000 images de champs de blé sous plusieurs conditions d'éclairage (temps ensoleillé et nuageux du matin au soir).



Figure 3- 4: Type 1: Convolvulus



Figure 3- 5: Type 2: Phalaris Paradoxa

Ces images RVB montrent les deux types de plantes à différents stades de croissance ; ils sont au format *png* et de différentes tailles, ce qui nous oblige à les redimensionner avant d'être utilisés en entrée du modèle CNN sous la forme 416x416. Puis la phase d'annotation attribue une légende (label) aux objets contenus dans l'image (adventices). Cette technique crée des données d'entraînement pour la vision par ordinateur afin d'entraîner notre modèle à apprendre à voir un élément comme des êtres humains [163]. Pour ce faire, nous avons utilisé l'application « LabelImg Annotations » (figure 3-6), qui se base sur la boîte englobante pour forcer les étiquettes à tracer une boîte au plus près des bords des objets clés de l'image, les points formant les cadres (en haut à gauche et en bas à droite) sont stockés dans un fichier XML. Ensuite, nous avons divisé les images en fractionnements d'entraînement, de validation et de test pour éviter que le modèle ne soit surajusté et pour évaluer le modèle avec des métriques générées à cet effet. La partie étendue de notre jeu de données (70%) est l'ensemble d'entraînement réservé à l'entraînement de nos modèles. La précision résultant de ces images après l'étape d'apprentissage sera prise en compte pour mémoriser la bonne sortie. Le deuxième ensemble de validation est une section distincte de l'ensemble de données (20 %) utilisé pendant l'apprentissage pour évaluer les performances de notre modèle en rapportant les métriques de validation en continu après chaque période d'apprentissage, comme la précision moyenne. Enfin, 10 % de notre ensemble de données a été

utilisé comme ensemble de test après les expériences d'entraînement pour avoir une idée de la performance finale du modèle [164].

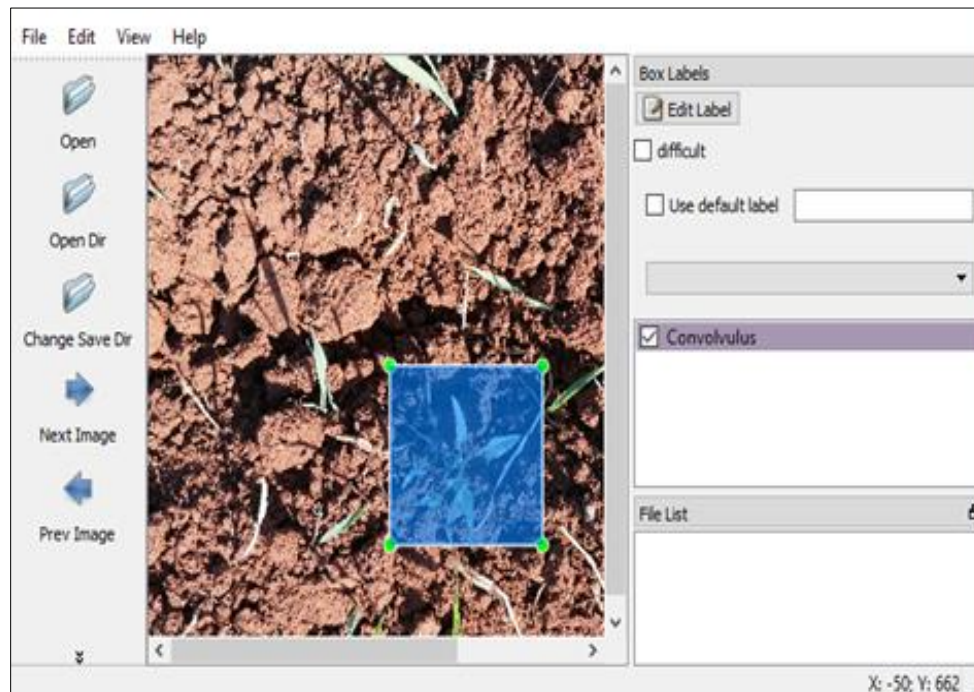


Figure 3- 6: L’annotation des boîtes englobantes des objets dans les images

La dernière phase de l'étape de préparation des données est l'augmentation des données (data-augmentation), qui est une méthode appliquée aux images de notre ensemble d'apprentissage pour produire des échantillons d'apprentissage nouveaux et différents. Cette méthode applique des techniques spécifiques au domaine aux images pour générer plus de données d'entraînement et améliorer les performances du modèle [165], Nous avons effectué ce processus sur la plateforme Kaggle qui fournit un certain nombre de services à cet effet. La figure 3-7 présente des exemples de certaines méthodes utilisées dans l'expérience qui nous donne plus de 3000 images après cette technique. Ces opérations n'ont pas été effectuées sur toutes les images, nous avons choisi uniquement les images qui contiennent un seul objet, ce qui justifie ce nombre.

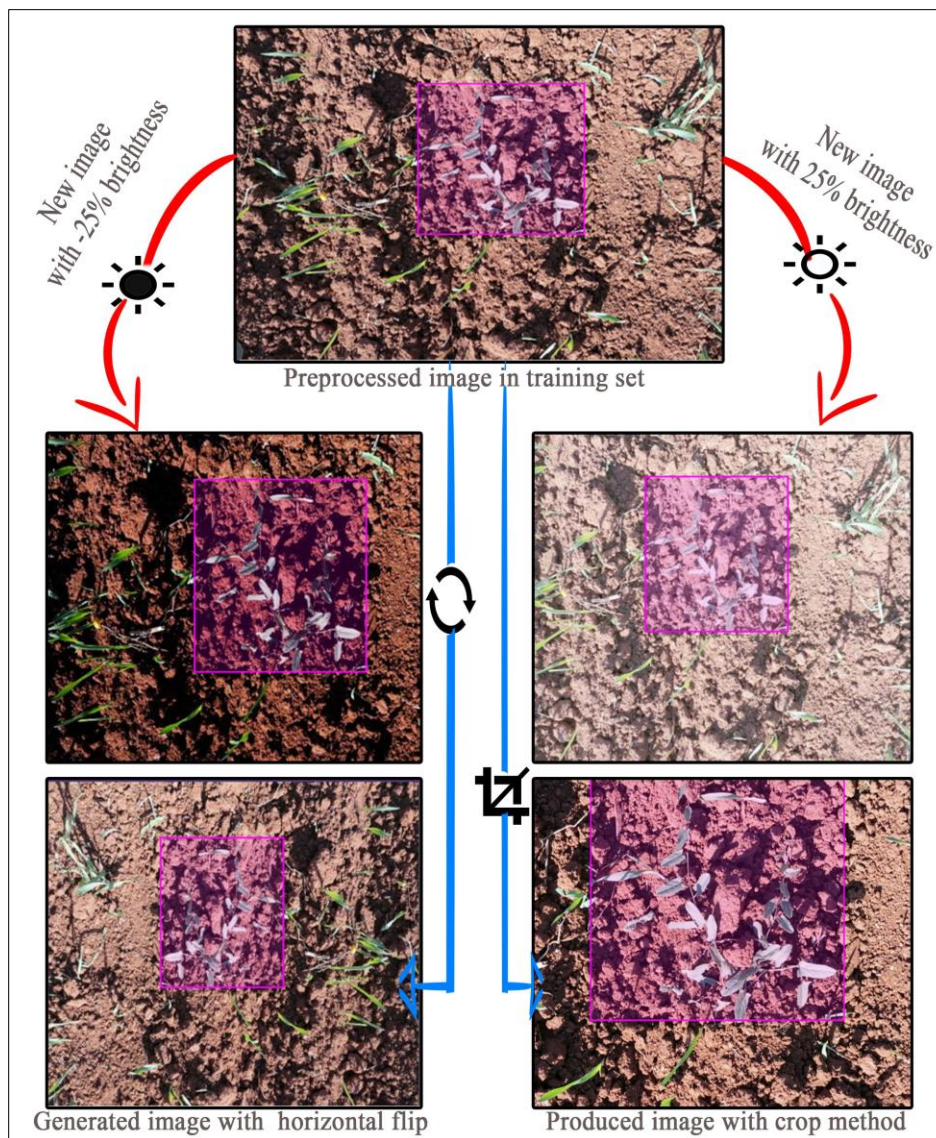


Figure 3- 7: Ensemble de méthodes d'augmentation de données appliquées

4. Résultats et discussion

Au cours de nos expériences, nous avons implémenté les quatre modèles pour les entraîner à notre ensemble de données. La configuration de ces modèles diffère de l'un à l'autre. Chaque modèle de détection d'objet a un Shell d'une configuration de préparation explicite pour chacun, donnée par les créateurs (fichier pipeline de base). Un point de contrôle pré-entraîné indique le fichier de poids pré-entraînés enregistré à partir du moment où le modèle a été entraîné sur un énorme ensemble de données. Nous spécifions également certains paramètres d'entraînement tels que le nombre d'itérations et d'étapes d'entraînement de la taille de l'image d'entrée. Il existe plusieurs métriques pour évaluer les performances des réseaux de neurones et des modèles

d'apprentissage en profondeur après les avoir entraînés sur notre ensemble de données, nous utilisons les métriques d'accuracy et calculons également l'erreur, l'accuracy mesure la précision du modèle dans l'organisation d'images comme positives. En général, pour évaluer les performances de l'entraînement d'un modèle de deep learning, les métriques de performance les plus courantes sont:

- Accuracy: c'est le nombre total de prédictions correctes sur le nombre total de prédictions effectuées, donné par la formule (3-1).

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + FN + TN} \quad (\text{Éq. 3-1})$$

- Precision (formule 3-2) : La précision c'est la proportion d'identifications positives (les classes positives réellement identifiées correctement).

$$\text{Precision} = \frac{TP}{TP + FP} \quad (\text{Éq. 3-2})$$

- Recall (formule 3-3) : c'est le pourcentage des positives réelles a été identifié correctement.

$$\text{Recall} = \frac{TP}{TP + FN} \quad (\text{Éq. 3-3})$$

- F1 (formule 3-4): a pondéré la moyenne de la précision et du rappel. Par conséquent, ce score prend en compte à la fois les faux positifs et les faux négatifs.

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (\text{Éq. 3-4})$$

- Une autre métrique donnée par la formule 3-5, qui peut être considérée comme le contraire de l'accuracy c'est le les prédictions fausses sur le total des prédictions réalisées.

$$\text{Error} = \frac{FP + FN}{TP + FP + FN + TN} \quad (\text{Éq. 3-5})$$

- Nous évaluons également la précision des modèles en exécutant l'inférence sur l'ensemble de données de test pour montrer des prédictions sur eux [166].

TN : Vrai Négatif

TP : Vrai Positif

FP : Faux Positif

FN : Faux Négatif

Pour visualiser les résultats obtenus pour les quatre modèles, nous illustrons dans ce qui suit, les résultats en termes d'accuracy et d'erreur pour chacun des quatre modèles.

Après avoir entraîné le modèle EfficientDet sur 3 500 itérations, nous obtenons des résultats par TensorBoard, comme suit :




Figure 3- 8: La performance de l'EfficientDet




Figure 3- 9: Taux d'erreur de l'EfficientDet

D'après les résultats obtenus, on note les remarques suivantes : D'après la figure 3-8, l'accuracy de l'entraînement augmente à chaque itération pour atteindre 52 % après 12 heures d'entraînement. Cela reflète qu'à chaque progression, le modèle apprend plus de données. Nous avons donc besoin de plus d'itérations pour obtenir plus de précision(accuracy). L'erreur d'apprentissage diminue avec le nombre d'itérations, atteignant 38 % (figure 3-9). Malgré l'accuracy moyenne de l'entraînement EfficientDet, nous avons eu des prédictions intéressantes sur les images de test comme indiqué sur la figure 3-10. Cela montre que nous n'avons besoin d'accélérer les performances qu'en modifiant des paramètres spécifiques, tels que le nombre d'étapes d'apprentissage (Epoch), les options d'augmentation de données sur l'ensemble de données, etc.



Figure 3- 10: Les prédictions sur les images de test

Après la fin de l'apprentissage de YOLOv5 sur 200 époques, nous évaluons ses performances par les métriques d'accuracy et d'erreur sur Tensorboard comme suit :




Figure 3- 11: La performance de YOLOv5




Figure 3- 12: Taux d'erreur pour YOLOv5

D'après les résultats ci-dessous, nous pouvons voir que les métriques de performance enregistrées sur Tensorboard ont montré une accuracy intéressante atteignant 82% (figure 3-11). Une erreur totale a diminué à 30 % (figure 3-12). L'exécution YOLOv5 est plus rapide que les autres modèles, environ 2 heures d'exécution. Cela signifie que les performances du modèle peuvent toujours s'améliorer à chaque époque.

Nous présentons les résultats de Detectron2 sur Tensorboard pour voir comment la procédure d'apprentissage a fonctionné sur 1500 itérations (car moins d'itérations n'a pas donné de résultat). Il y a beaucoup de métriques intéressantes dans cet outil d'évaluation. Nous nous concentrons sur le total de la perte et de l'accuracy; comme le montrent les figures ci-dessous :




Figure 3- 13: La performance de Detectron2




Figure 3- 14: Taux d'erreur pour Detectron2

Après analyse des résultats acquis (figure 3-13 et 3-14), on peut voir les commentaires ci-joints : D'après la figure 3-13, l'accuracy de l'entraînement augmente avec le nombre de pas. Cela reflète qu'à chaque itération, le modèle apprend plus d'informations. Nous devons changer le nombre

d'itérations si l'accuracy de s'augmente encore, changer vers le bas en cas de surajustement. L'entraînement est arrivé à 97% sur les dernières étapes, après 5h d'exécution.

Les résultats de Faster R-CNN affichés sur l'outil Tensorboard après 10 000 itérations montrent les métriques suivantes :




Figure 3- 15: La performance de Faster R-CNN




Figure 3- 16: Taux d'erreur de Faster R-CNN

Les chiffres ci-dessus montrent que l'accuracy d'apprentissage augmente à chaque étape pour atteindre 45 % après 10 heures (figure 3-15). Cela reflète le nombre d'itérations est un facteur essentiel où le modèle apprend plus d'informations. Bien que le nombre de pas soit élevé par rapport aux autres modèles, l'accuracy est moyenne. De même, l'erreur change avec la progression de l'apprentissage, il s'augmente et diminue, dans les dernières étapes, il atteint 80 % (figure 3-16). Après avoir analysé les résultats obtenus sur tous les modèles de détection d'objets open source, nous comparons les résultats des différents détecteurs en termes d'accuracy et d'erreur. À cet effet, les résultats obtenus par ces détecteurs d'objets open source sur nos données sont résumés dans le tableau 3-1.

Tableau 3- 1. Les performances des modèles étudiés

Modèle	Type	Résultats sur COCO	Nombre d'itérations d'apprentissage	Résultats sur notre dataset	Taux d'erreur sur notre dataset	Durée d'apprentissage
EfficientDet	Détecteur « One stage »	55.1%	3500	52%	38%	12 heures
YOLOv5	Détecteur « One stage »	50.1%	200	82%	30%	2 heures
Detectron2	Détecteur « One stage »	64.31%	1500	97%	42%	5 heures
Faster R-CNN	Détecteur « Two stages »	36.8%	10 000	45%	80%	10 heures

Le tableau montre le type de modèle open source de notre expérience ainsi que le nombre d'itérations. Les résultats obtenus sur les jeux de données COCO, ainsi que ceux obtenus sur notre

jeu de données, qui s'expriment en termes d'accuracy d'apprentissage et d'erreur enfin de temps d'exécution. En outre, on retient qu'il y a une différence dans le nombre d'itérations d'entraînement pour chaque modèle. Au début, nous avons commencé avec le même nombre d'itérations, mais après l'entraînement, il nous devient clair dans chaque cas que nous avons encore besoin de plus d'itérations pour atteindre de meilleurs résultats, alors nous augmentons le nombre d'itérations à chaque fois. À chaque entraînement nous nous assurons que les résultats sont bons et qu'il n'y a pas de Overfitting, ou que nous avons encore besoin de plus d'étapes. Les résultats obtenus s'amélioreraient au fur et à mesure que nous augmentions le nombre d'itérations car plus nous avons d'itérations, plus nous obtenons plus d'accuracy et peu d'erreur (mais nous devrions faire attention au surajustement). Le jeu de données est également un élément déterminant dans les modèles de détection d'objets. Il est nécessaire de disposer d'un grand ensemble de données pour obtenir de meilleurs résultats pour la plupart des modèles. Aussi, obtenir de bons résultats nécessite d'utiliser un GPU au lieu d'un CPU [167]. En outre, nous sommes susceptibles d'obtenir plus de performances lorsque l'abandon est utilisé.

Le modèle YOLOv5 a présenté les meilleurs résultats trouvés par rapport aux autres modèles en termes d'accuracy 82%. Le temps d'exécution était très raisonnable par rapport au nombre d'époques et à la taille de notre base de données. Cependant, YOLOv5 a des résultats moyens sur le jeu de données COCO [168], mais il prouve qu'il s'agit d'un modèle efficace sur un jeu de données moyen en un temps réduit. Nous enregistrons donc ces poids pour les utiliser dans un système robotique de détection de mauvaises herbes basé sur Raspberry pi4. Cela contribuera à détecter les mauvaises herbes en temps réel pour réaliser une pulvérisation localisée des mauvaises herbes au lieu de les propager à grande échelle, ce qui sera bénéfique en termes de quantité d'herbicides exploités, donc protège l'environnement et fait gagner du temps, ce sera une prise de décision automatisée sans aucune implication humaine.

5. Conclusion

Les réseaux de neurones profonds sont réputés pour leur capacité à traiter les informations visuelles. Ces dernières années, ils sont devenus une partie importante de nombreuses applications de vision par ordinateur, nous avons choisi leur application à la découverte des mauvaises herbes, ce choix est prouvé par les études que nous avons menées dans les chapitres précédents. L'apprentissage profond en agriculture fait toujours l'objet de recherches et de diligence. Dans ce chapitre, nous avons présenté une approche comparative de basée sur les modèles de détection

d'objets open source, pour cela, nous avons utilisé quatre modèles récents avec des architectures différentes. Nous avons montré les différents résultats obtenus en termes d'accuracy et d'erreur sur notre jeu de données préparé. La comparaison des résultats obtenus a montré que le nombre d'itérations, la taille du jeu de données, l'optimisation de l'affectation GPU / CPU et l'augmentation des données sont des facteurs importants pour avoir de meilleurs résultats. Les résultats obtenus nous ont prouvé que YOLO v5 est un modèle rapide et léger que nous considérons comme un meilleur choix à utiliser dans un système embarqué de détection des mauvaises herbes. Dans le chapitre suivant, nous effectuerons une série de tests pour préparer et créer des modèles d'apprentissage en profondeur et pour les entraîner sur nos données contenant des mauvaises herbes de notre environnement. L'objectif est de découvrir des moyens possibles d'améliorer les résultats et de suggérer de nouvelles façons d'y parvenir.

CHAPITRE

IV

**ÉTUDES DE CAS : AMÉLIORATION DES MODÈLES
DE CNN POUR LA DÉTECTION DES MAUVAISES
HERBES**

1. Introduction

Les mauvaises herbes sont clairement classées comme le principal problème de parasites dans l'agriculture ancienne et moderne [169]. Les mauvaises herbes sont des plantes qui poussent spontanément sur les sols agricoles où elles sont omniprésentes et indésirables parmi toutes les cultures du sol agricole. La croissance de ces plantes, si elle n'est pas gérée, a une grande capacité à réduire la productivité, à produire un impact énorme sur les valeurs de la biodiversité, à causer des dommages, à rendre difficile le fonctionnement des machines. Les effets négatifs des mauvaises herbes sur les cultures comprennent aussi la concurrence pour l'eau, la lumière, les nutriments et l'espace, l'augmentation des coûts de production, la difficulté de la récolte, la dépréciation de la qualité du produit, l'augmentation du risque de parasites et de maladies et la diminution de la valeur commerciale des zones cultivées [170].

L'application d'herbicides donne de meilleurs résultats si le traitement est ciblé sur la catégorie spécifique de mauvaises herbes. La connaissance de l'infestation des mauvaises herbes est une procédure fondamentale pour l'utilisation de mesures préventives dans leur contrôle [171]. Afin de parvenir à un contrôle des mauvaises herbes spécifique à une zone et de réduire le coût global et l'impact négatif de l'utilisation d'herbicides inutiles sur la santé humaine et les cultures, il est important de disposer de méthodes permettant de quantifier et d'analyser la distribution de l'infestation des mauvaises herbes de manière rapide et économique, alors une méthode plus pratique que l'observation systématique des cultures est nécessaire.

La gestion des mauvaises herbes spécifiques au site est l'une des pratiques associées à l'agriculture de précision. La gestion des mauvaises herbes spécifiques au site est l'une des mesures efficaces pour réduire l'utilisation des pesticides, économiser sur les coûts des herbicides, améliorer le contrôle des mauvaises herbes et éviter une pollution inutile de l'environnement.

La localisation automatique des mauvaises herbes à l'aide d'algorithmes d'apprentissage profond a été étudiée ces dernières années. Ces systèmes de classification des mauvaises herbes basés sur l'apprentissage profond nécessitent des informations détaillées sur les terres agricoles, les champs et les caractéristiques des mauvaises herbes et des cultures individuelles (c'est-à-dire un grand ensemble de données sur les mauvaises herbes et les cultures). Avec le développement dans le domaine de la vision par des ordinateurs [172], il est possible de faire un large traitement et une observation régulière avec les algorithmes avancés existants.

La détection des mauvaises herbes et des plantes à partir d'images est cependant une tâche difficile, car les mauvaises herbes et les plantes ont souvent des caractéristiques colorées et spectrales

similaires. Le processus de classification est plus difficile lorsqu'il y a occlusion des cultures et que l'environnement de fond (c'est-à-dire le sol) est complexe. Les changements d'illumination et l'effet d'ombrage sont également des problèmes difficiles à résoudre.

Les classificateurs utilisés à cette fin, comme Support Vector Machines et les réseaux de neurones traditionnels (MLP), dépendent de bons extracteurs de caractéristiques [173]. Le facteur clé du deep learning est que son extraction de caractéristiques est apprise automatiquement à partir des données brutes [174]. Ses couches d'attributs ne sont pas modélisées manuellement et il n'est pas nécessaire d'utiliser des algorithmes d'extraction pour effectuer l'apprentissage et la classification du réseau convolutif. Ainsi, on s'attend à ce que cette technique ait beaucoup plus de succès dans un avenir proche, car elle nécessite peu d'ingénierie à la main et peut bénéficier d'une augmentation de la capacité de calcul et des données.

Dans ce chapitre, nous avons proposé des pipelines pour détecter et masquer la présence de mauvaises herbes dans une image. Les données de l'image sont prétraitées et introduites dans des modèles différents de deep learning. Chaque modèle représente l'objet d'une étude indépendante dans laquelle des données spéciales ont été utilisées. À la fin, nous avons comparé les retours de chaque approche et examiné les performances de chaque modèle en termes de précision de temps, etc. Cette deuxième contribution a fait l'objet de 3 articles [175, 176, 177] publiés dans des revues indexés Scopus dans lesquels nous avons exploré des techniques de création et d'optimisation et d'amélioration des modèles de deep learning au profit d'une agriculture digitale.

2. Méthodes et outils

Cette section définit les méthodes et l'environnement requis pour implémenter les modèles de nos études. Nous travaillons avec python 3.6 comme langage de programmation, les bibliothèques TensorFlow et Keras pour l'apprentissage et la classification [178]. Pour améliorer les performances des modèles, nous utilisons quelques techniques simples et efficaces comme l'augmentation des données, Dropout [177] et Tensorboard pour la visualisation des statistiques et logs.

2.1 Datasets utilisés

L'un des facteurs importants affectant la qualité des modèles de l'entraînement est l'ensemble de données, plus nous avons de grands ensembles de données bien préparés, plus la précision de l'entraînement est élevée [179]. Les données qui ont servi à entraîner nos modèles lors de ces expérimentations varient d'une étude à l'autre. Nous avons utilisé les images recueillies sur le

terrain à l'aide d'un appareil photo officiel dans une autre expérience. Nous combinons ces données recueillies avec des données provenant d'une base de données publique. Dans d'autres, on utilise une partie des données précédemment utilisées dans une étude et on y ajoute d'autres données. Le plus important est de collecter un grand nombre d'images (de mauvaises herbes, ainsi images des cultures), ce qui affectera sans aucun doute les résultats obtenus. Nous avons apporté des modifications de prétraitement à ces images (redimensionnement, contraste, mosaïque). Nous avons également ajouté des techniques d'augmentation des données (recadrage, rotation, retournement) pour produire plus d'images d'entraînement qui peuvent augmenter la précision du modèle. Ces images appartiennent à différentes classes selon chaque étude. Le tableau 4-1 présente les détails de ces datasets selon chaque étude.

Tableau 4- 1. Détails des datasets utilisés dans les trois études

Expériences	Nombre des images	Nombre des classes
Expérience 1 [175]	2669	6
Expérience 2 [176]	3000	2
Expérience 3 [177]	3000	4

2.2 Environnement matériel

L'environnement matériel diffère d'une expérience à l'autre, parfois nous utilisons l'ordinateur personnel avec la configuration que nous avons précédemment (HP i7 CPU 2.40 GHZ, Nvidia GeForce GT525M, 8G de RAM), en utilisant GPU (Graphics Processing Units) au lieu de CPU (Central Processing Unit) pour l'entraînement, car la solution GPU est la solution la plus optimale dans les opérations des réseaux de neurones avec des données d'images. Nous avons également testé l'environnement de Google Colab comme un service cloud, offert par Google, basé sur Jupyter Notebook et destiné à l'entraînement des modèles de ML. Cette plateforme permet d'entraîner des modèles de machine learning directement dans le cloud utilisant un processeur graphique GPU. Sans donc avoir besoin d'installer quoi que ce soit sur notre ordinateur à l'exception d'un navigateur. Le problème ici est dans le cas de données très volumineuses et dans le cas d'un modèle d'apprentissage en profondeur complexe qui nécessite un abonnement, car l'espace offert est limité, aussi la période d'apprentissage disponible n'est que de dix heures continues. Ces différences dans les paramètres matériels visent à découvrir l'effet de l'environnement matériel sur l'apprentissage d'un algorithme et comment déterminer l'espace distinct qui nous donne de meilleurs résultats.

3. Expérience 1 : CNN pour l'identification des mauvaises herbes

Notre objectif dans cette étude est l'identification et le contrôle des mauvaises herbes dans les champs de betteraves sucrières, en particulier la création et l'amélioration d'un modèle de réseaux de neurones convolutifs et son entraînement selon notre ensemble de données pour prédire et identifier les souches de mauvaises herbes les plus populaires dans la région de Béni- Mellal Khenifra, Maroc. Tout cela peut aider à sélectionner des herbicides qui agissent sur les mauvaises herbes identifiées. Nous explorons la capacité de python pour adapter et améliorer notre modèle CNN formé sur nos jeux de données [180].

3.1 Architecture de base

Comme le montrent les figures 4-1 et 4-2, lors de notre expérimentation, nous avons créé un modèle de base. Il est composé de deux couches de convolution et de deux couches de Maxpooling et de deux couches Fully-connected. L'image d'entrée est de taille 98*98. L'image entre à la première couche de convolution (CONV). Cette couche est composée de 256 filtres de taille 3*3, la fonction d'activation ReLU (Rectified Linear Units) est utilisée ; cette fonction ($F(x)=\max(0,x)$) force les neurones à revenir positifs. Après cette convolution, 256 cartes de caractéristiques (feature maps) de taille 98*98 seront créées. Maxpooling (POOL) est ensuite appliqué pour réduire la taille et les paramètres de l'image. À la sortie de cette couche, nous aurons 256 cartes de caractéristiques de taille 49*49. Nous répétons la même chose avec la couche convolutive numéro deux (composée de 256 filtres). La fonction d'activation ReLU est toujours appliquée à chaque convolution. Une couche Maxpooling est appliquée après la couche de convolution numéro deux en sortie, nous aurons 256 cartes de caractéristiques de taille 23*23. Le vecteur de caractéristiques résultant des convolutions a une dimension de 135424.

Ensuite, nous utilisons un réseau de neurones composé de deux couches Fully-connected (FC). La première couche a 64 neurones, la deuxième couche est un Softmax, ce qui nous permet de calculer la distribution de probabilité de nos classes (six classes dans l'ensemble de données).




Figure 4- 1: Architecture du modèle

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 98, 98, 256)	2560
activation (Activation)	(None, 98, 98, 256)	0
max_pooling2d (MaxPooling2D)	(None, 49, 49, 256)	0
conv2d_1 (Conv2D)	(None, 47, 47, 256)	590080
activation_1 (Activation)	(None, 47, 47, 256)	0
max_pooling2d_1 (MaxPooling2D)	(None, 23, 23, 256)	0
flatten (Flatten)	(None, 135424)	0
dense (Dense)	(None, 64)	8667200
dense_1 (Dense)	(None, 6)	390
activation_2 (Activation)	(None, 6)	0
Total params: 9,260,230		
Trainable params: 9,260,230		
Non-trainable params: 0		

Figure 4- 2: Configuration du modèle

3.2 Résultats

Après analyse des résultats obtenus dans la première étude, les remarques suivantes sont notées : d'après les deux figures 4-3 et 4-4, la précision de l'apprentissage augmente avec le nombre

d'itérations (epochs). Cela reflète qu'à chaque itération, notre modèle apprend plus d'informations pour arriver à 73% de précision. Cependant, il commence finalement à tomber après la huitième itération. Cela devrait nous alerter sur le fait que nous commençons presque certainement à faire du surentraînement (Overfitting). La raison pour laquelle cela se produit est que le modèle essaie constamment de réduire la perte dans l'échantillon. À un moment donné, le modèle commence simplement à mémoriser les données d'entrée au lieu d'apprendre des choses générales sur les données réelles, ce qui signifie que toute nouvelle donnée que nous tentons d'alimenter le modèle fonctionnera mal. De même, l'erreur d'apprentissage et de validation diminue avec le nombre d'itérations et après la huitième époque, elle commence à augmenter. Ainsi, nous aurons besoin de plus d'informations pour entraîner notre modèle, nous devons donc chercher une solution qui réduit le surajustement, par exemple : augmentant le nombre d'itérations et modifiant d'autres paramètres, ce qui fait l'objet de la séquence suivante.




Figure 4- 3: Les performances du modèle




Figure 4- 4: Le taux d'erreur du modèle

Ici, nous devons souligner que le modèle que nous avons utilisé pour l'entraînement est le modèle de départ que nous avons défini ci-dessus, nous y avons utilisé des données préliminaires. Cela a donné des résultats moyens avec beaucoup de surentraînement. Par conséquent, nous proposerons des solutions pour augmenter les résultats obtenus. Après quelques époques, nous avons une précision de validation de 73 %, mais nous devrions probablement discuter de la manière dont nous pouvons optimiser ce modèle pour améliorer cette valeur. Comme nous en avons discuté dans la séquence précédente ; nous devons réduire le surajustement, pour cela, il existe de nombreuses solutions. Nous citons 5 : techniques Augmentation des données, Régularisation, Arrêt anticipé, Simplification du modèle et décrochage, en anglais sont respectivement : Data Augmentation, Regularization, Early Stopping, Simplifying the Model, Dropout. Pour notre cas, nous nous concentrerons sur la solution d'augmentation de données. Nous utiliserons également l'outil TensorBoard, qui est une application puissante fournie avec TensorFlow et qui nous aide à visualiser nos modèles au fur et à mesure qu'ils sont entraînés, il aide également à créer un flux de travail pour optimiser l'architecture de notre modèle.

Après avoir appliqué la technique d'augmentation de données à nos données, nous passerons à l'étape la plus importante, à savoir comment améliorer l'efficacité du modèle à l'aide de TensorBoard et à l'aide du code python. Des ajustements doivent être apportés aux paramètres du modèle afin de trouver les bons paramètres grâce auxquels nous obtenons de meilleurs résultats. Les éléments les plus élémentaires que nous devons modifier sont les couches et les nœuds par couche et 0, 1 ou 2 couches denses, ainsi que d'autres paramètres tels que la variation de la taille des couches (layer sizes), des taux d'apprentissage (learning rates) et des fonctions d'activation. Grâce au code python nous créons une boucle qui permet de créer, d'assembler et de tester un

ensemble de combinaisons (80 modèles) pour choisir la meilleure d'entre elles qui donne les bons résultats (haute précision visualisée sur l'application Tensorboard.

Chaque modèle créé de cette manière est nommé avec les paramètres utilisés (conv_layer, layer_size, dense_layer) pour faciliter le choix et le distinguer parmi ce grand nombre comme indiqué sur la figure 4-5.

```

1-conv-32-nodes-0-dense-1599243547
2-conv-32-nodes-0-dense-1599243547
3-conv-32-nodes-0-dense-1599243547
4-conv-32-nodes-0-dense-1599243547
1-conv-64-nodes-0-dense-1599243547
2-conv-64-nodes-0-dense-1599243547
3-conv-64-nodes-0-dense-1599243547
...
3-conv-256-nodes-3-dense-1599243547
4-conv-256-nodes-3-dense-1599243547
1-conv-512-nodes-3-dense-1599243547
2-conv-512-nodes-3-dense-1599243547
3-conv-512-nodes-3-dense-1599243547
4-conv-512-nodes-3-dense-1599243547
    
```

Figure 4- 5: Les noms des modèles créées

Les figures 4-6 et 4-7 ci-dessous capturées à partir de Tensorboard, montrent une visualisation des 80 modèles créés ci-dessus. Nous pourrions être tentés de prendre le modèle de précision de validation le plus élevé, mais à la place, nous avons tendance à opter pour les modèles de perte de validation les plus faibles dans le graphique résultant. Par conséquent, un zoom sur le graphique de précision de validation ou le graphique de perte de validation nous a permis de choisir et de vérifier certains des meilleurs modèles.




Figure 4- 6: Les performances de 80 modèles créés

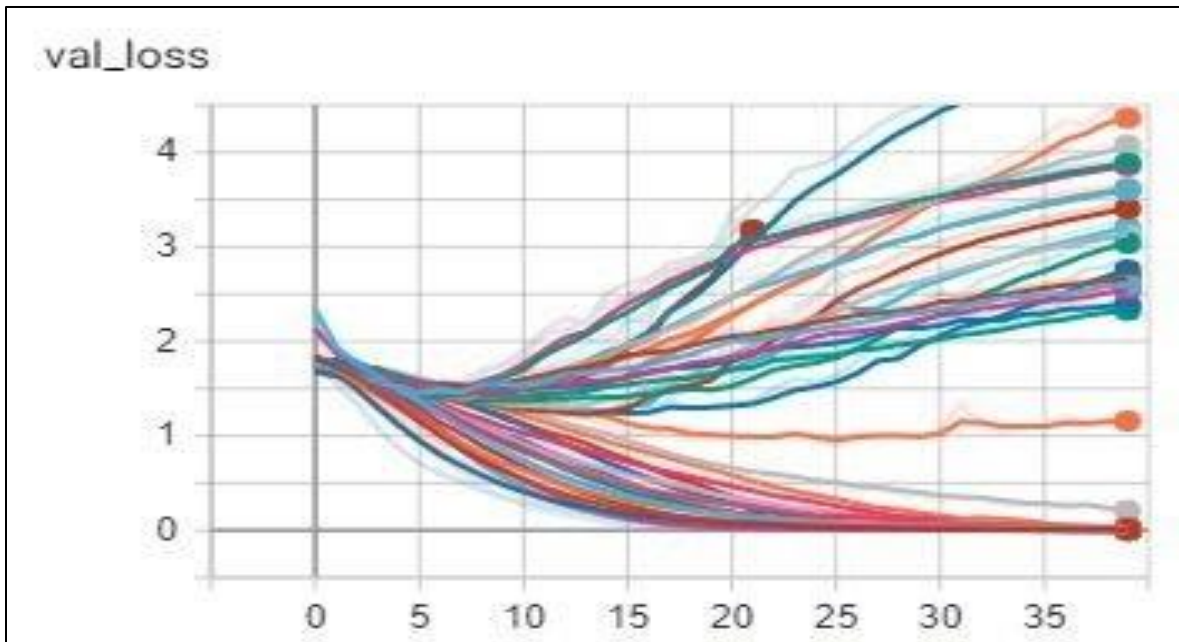


Figure 4- 7: Le taux d'erreur pour les 80 modèles

Après avoir zoomé sur le graphique de la figure 4-7, voici les 3 premiers modèles avec la plus grande précision (figure 4-8). On peut se contenter de 0 dense et 1 couche convolutive et 128 nœuds par couche.




Figure 4- 8: Trois premiers modèles avec la meilleure performance

Changer certains paramètres, utiliser un modèle avec technique d'augmentation de données et choisir 0 couche dense, 1 couche convolutive et 128 nœuds par couche, avec plus d'époques (40), avait développé l'accuracy à 82% avec 20 heures de l'entraînement (figure 4-9).

```

-----
84/84 [=====]- 11s 127ms/step -loss: 0.5166 - sparse_categorical_accuracy: 0.8277
-----
Test accuracy: 0.827650785446167
-----

```

Figure 4- 9: La performance du modèle amélioré

4. Expérience 2 : YOLO V5 pour la reconnaissance des adventices

Dans cette étude, nous proposons un modèle d'apprentissage profond qui cherche à identifier la présence d'objets pertinents (mauvaises herbes) dans une zone (culture de blé) en temps réel et classer ces objets pour l'aide à la décision. Nous avons proposé de mettre en œuvre ce modèle CNN sur un système intelligent pour détecter et localiser les types de mauvaises herbes connues dans les cultures de blé dans la région de Beni Mellal-Khenifra, au Maroc. Ce système intelligent aidera les agriculteurs à identifier plus tôt les espèces de mauvaises herbes et à les classer, afin de réaliser une pulvérisation localisée pour les éliminer et permettre aux cultures de pousser librement en bénéficiant des sels minéraux et de l'eau. Tout cela dans le but de préserver l'environnement et de réduire le coût de l'opération.

4.1 Architecture utilisée

Au cours de nos expérimentations, nous avons utilisé un modèle YOLO avec quelques interventions dessus. Ainsi, nous avons réduit le nombre d'échelles de détection à deux échelles [181]. Ce modèle avait dans l'échelle des multiplicateurs de la largeur 0,50 et de la profondeur 0,33 (width 0.50 et depth) [182]. Il est composé d'une partie dorsale (backbone) où notre image originale 416*416*3 est entrée dans la structure Focus (Focus structure). L'opération de découpage est d'abord utilisée pour avoir une carte de caractéristiques de 208*208*12, puis après une opération de convolution de 32 noyaux de convolution, le dernier changement nous donne une carte de caractéristiques de 208*208*32. De plus, une structure CSP (Cross-Stage-Partial) est conçue dans le Backbone pour l'extraction de caractéristiques [183].

De plus, une partie Neck utilise FPN (Feature Pyramid Network) et PAN (Path Aggregation Network) pour faire des prédictions de détection d'objets à différents niveaux d'échelle [184]. Enfin, le modèle utilise *GIOU_Loss* comme fonction de perte de la Boîte englobante en sortie [185]. Concernant la configuration des différents paramètres des différentes couches (283 couches), on a laissé la même structure que le petit YOLOv5 de base comme il est mentionné dans les figures 4-10 et 4-11.

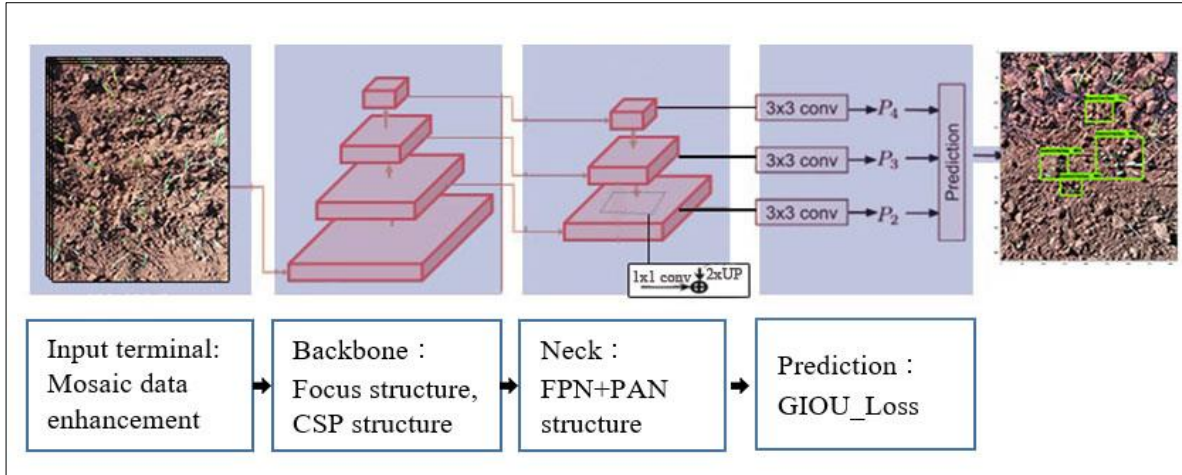


Figure 4- 10: Architecture de DL

```

depth_multiple: 0.33 # model depth multiple
width_multiple: 0.50 # layer channel multiple

# anchors
anchors:
  - [10,13, 16,30, 33,23] # P3/8
  - [30,61, 62,45, 59,119] # P4/16
  - [116,90, 156,198, 373,326] # P5/32

# YOLOv5 backbone
backbone:
  # [from, number, module, args]
  [[-1, 1, Focus, [64, 3]], # 0-P1/2
  [-1, 1, Conv, [128, 3, 2]], # 1-P2/4
  [-1, 3, BottleneckCSP, [128]],
  [-1, 1, Conv, [256, 3, 2]], # 3-P3/8
  [-1, 9, BottleneckCSP, [256]],
  [-1, 1, Conv, [512, 3, 2]], # 5-P4/16
  [-1, 9, BottleneckCSP, [512]],
  [-1, 1, Conv, [1024, 3, 2]], # 7-P5/32
  [-1, 1, SPP, [1024, [5, 9, 13]]],
  [-1, 3, BottleneckCSP, [1024, False]], # 9
  ]

# YOLOv5 head
head:
  [[-1, 1, Conv, [512, 1, 1]],
  [-1, 1, nn.Upsample, [None, 2, 'nearest']],
  [[-1, 6], 1, Concat, [1]], # cat backbone P4
  [-1, 3, BottleneckCSP, [512, False]], # 13

  [-1, 1, Conv, [256, 1, 1]],
  [-1, 1, nn.Upsample, [None, 2, 'nearest']],
  [[-1, 4], 1, Concat, [1]], # cat backbone P3
  [-1, 3, BottleneckCSP, [256, False]], # 17 (P3/8-small)

  [-1, 1, Conv, [256, 3, 2]],
  [[-1, 14], 1, Concat, [1]], # cat head P4
  [-1, 3, BottleneckCSP, [512, False]], # 20 (P4/16-medium)

  [-1, 1, Conv, [512, 3, 2]],
  [[-1, 10], 1, Concat, [1]], # cat head P5
  [-1, 3, BottleneckCSP, [1024, False]], # 23 (P5/32-large)

  [[17, 20, 23], 1, Detect, [nc, anchors]], # Detect(P3, P4, P5)
  ]

```

Figure 4- 11: Configuration du modèle

4.2 Résultats

Sur des données personnalisées préparées dans la deuxième expérience, nous avons entraîné le modèle configuré ci-dessus pour 200 époques, ce processus génère des hyperparamètres de descente de gradient qui contrôlent le nombre de passages complets à travers l'ensemble de

données de l'entraînement, qui génèrent 7255094 paramètres à travers 283 couches comme le présente la figure 4-12.

3	-1	1	73984	models.common.Conv	[64, 128, 3, 2]
4	-1	1	161152	models.common.BottleneckCSP	[128, 128, 3]
5	-1	1	295424	models.common.Conv	[128, 256, 3, 2]
6	-1	1	641792	models.common.BottleneckCSP	[256, 256, 3]
7	-1	1	1180672	models.common.Conv	[256, 512, 3, 2]
8	-1	1	656896	models.common.SPP	[512, 512, [5, 9, 13]]
9	-1	1	1248768	models.common.BottleneckCSP	[512, 512, 1, False]
10	-1	1	131584	models.common.Conv	[512, 256, 1, 1]
11	-1	1	0	torch.nn.modules.upsampling.Upsample	[None, 2, 'nearest']
12	[-1, 6]	1	0	models.common.Concat	[1]
13	-1	1	378624	models.common.BottleneckCSP	[512, 256, 1, False]
14	-1	1	33024	models.common.Conv	[256, 128, 1, 1]
15	-1	1	0	torch.nn.modules.upsampling.Upsample	[None, 2, 'nearest']
16	[-1, 4]	1	0	models.common.Concat	[1]
17	-1	1	95104	models.common.BottleneckCSP	[256, 128, 1, False]
18	-1	1	147712	models.common.Conv	[128, 128, 3, 2]
19	[-1, 14]	1	0	models.common.Concat	[1]
20	-1	1	313088	models.common.BottleneckCSP	[256, 256, 1, False]
21	-1	1	590336	models.common.Conv	[256, 256, 3, 2]
22	[-1, 10]	1	0	models.common.Concat	[1]
23	-1	1	1248768	models.common.BottleneckCSP	[512, 512, 1, False]
24	[17, 20, 23]	1	16182	models.yolo.Detect	[1, [[10, 13, 16, 30, 33, 23], [30, 61, 62, 45, 59, 119], [116,

Model Summary: 283 layers, 7255094 parameters, 7255094 gradients

Figure 4- 12: Détails du modèle utilisé

La section suivante illustre les résultats obtenus en termes de Recall de précision et de mAP précision moyenne (mean average precision) :




Figure 4- 13: Les performances de notre modèle

Comme le montrent les résultats de la figure 4-13, nous avons essayé 200 époques, nous avons obtenu de bons résultats, l'accuracy et la précision de l'apprentissage augmente avec le nombre de périodes ; cela reflète que le modèle apprend plus d'informations à chaque période. Le modèle est arrivé à une précision de 83 %, ce qui signifie que le modèle atteint une précision élevée. De plus, le Recall atteint 93 % signifie que le modèle est efficace pour identifier les données pertinentes ; l'entraînement renvoie une mAP de 94,4 % à 0,5. Les prédictions d'étiquettes sur les images de

l'ensemble de test montrent également une détection précise. Par conséquent, ces expériences ont démontré de bons résultats dans l'exécution du modèle CNN pour traiter la classification des mauvaises herbes en temps réel. Le résultat principal de cette étude démontre l'efficacité de YOLO et sa grande capacité à identifier les mauvaises herbes en un temps court et réel, la précision obtenue ci-dessus est très intéressante, montre que ce modèle est précis et rapide.

5. Expérience 3 : CNN basé sur des méthodes de régularisation pour la détection des mauvaises herbes

Le problème majeur avec l'apprentissage en profondeur est de savoir comment créer un modèle qui fonctionne bien, non seulement sur l'ensemble d'apprentissages, mais aussi sur l'ensemble de validation. De nombreuses approches utilisées dans les réseaux de neurones sont explicitement conçues pour réduire le surajustement, éventuellement au détriment de l'augmentation de la précision de la validation et de l'entraînement. Dans cette expérience, nous avons proposé un modèle CNN pour classer les mauvaises herbes. Nous avons proposé des techniques d'optimisation pour améliorer les résultats obtenus. Une technique de base (Dropout) est proposée pour minimiser le surajustement (Overfitting), nous l'avons intégrée dans un modèle de réseau de neurones convolutifs pour classer les espèces de mauvaises herbes et voir comment cela impacte les performances.

5.1 Architecture de DL

Notre objectif au cours de cette étude est de découvrir les méthodes de régularisation et comment le Dropout est un facteur important qui élimine le surajustement, pour cela, nous avons implémenté un modèle CNN simple et défini leurs couches et hyperparamètres afin de les entraîner sur notre jeu de données préparé.

L'architecture utilisée dans cette étude est structurée comme indiqué sur la figure 4-14. Tout d'abord, nous n'avons pas intégré la technique Dropout pour analyser les résultats avant et après Dropout. Le modèle est exécuté sur 20 époques, il nous a donné des résultats qui seront discutés dans la section suivante. Quant aux paramètres de ce modèle, nous l'avons dérivé de plusieurs expériences, y compris l'expérience que nous avons réalisée dans la première étude [175] pour bien présenter la structure du modèle et mettre chaque couche à sa place.

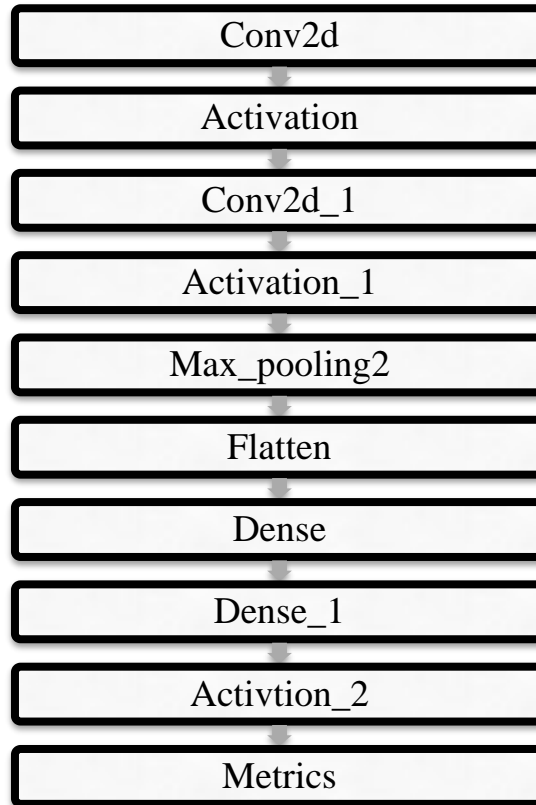


Figure 4- 14: Architecture du modèle avant la méthode Dropout

Dans un second temps nous intégrons la solution de décrochage(Dropout), pour montrer la différence entre le premier et le second modèle et savoir l'effet de cette solution. Un Dropout de 0,5 signifie que chaque neurone de sortie de la couche entièrement connectée a 50 % de chances d'être conservé. De plus, une autre couche de Dropout à la sortie du premier Dense avec une probabilité de 25%. Le décrochage 0,75 a également été placé après la phase de regroupement (Pooling) comme indiqué sur la figure 4-15. Cette technique désactive de manière aléatoire les neurones de notre réseau afin qu'il soit redondant et puisse trouver de nouvelles façons de résoudre le problème de surajustement.

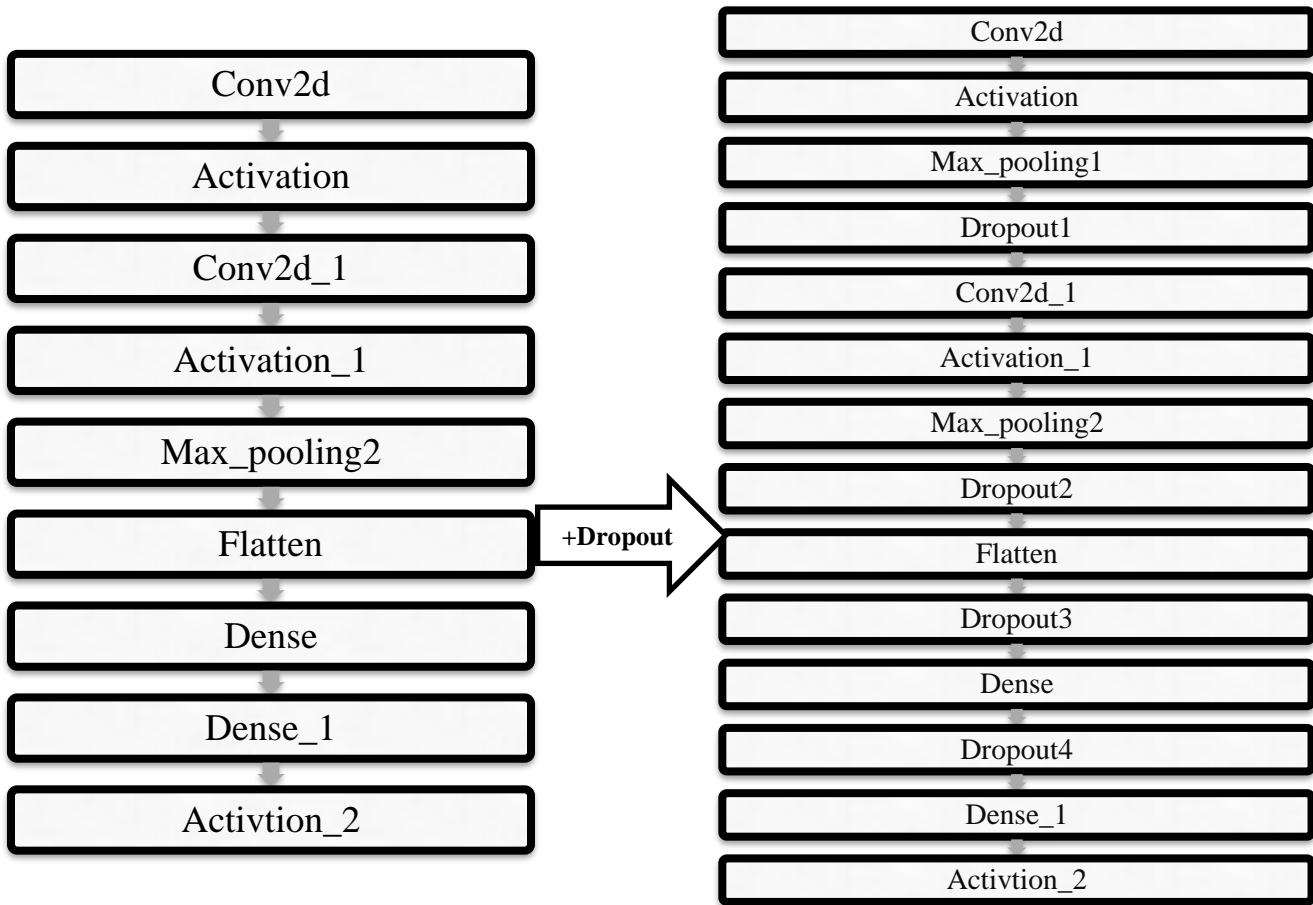


Figure 4- 15: L'ajout de la méthode Dropout

5.2 Résultats

Nous exécutons le modèle de la troisième étude sur notre ensemble de données en 20 itérations à l'aide de Python. Les résultats obtenus sont visualisés sur l'outil Tensorboard. La validation du modèle consiste à évaluer la capacité du modèle entraîné à généraliser à de nouveaux échantillons. L'accuracy de l'entraînement a également été utilisée comme estimateur pour classer le modèle dans une approche de sélection de variables. La figure 4-16 illustre les résultats du modèle avant l'introduction de la technique Dropout, comme nous l'avons indiqué dans la figure 4-14.




Figure 4- 16: L'accuracy de l'entraînement et de la validation avant le Dropout

L'écart entre l'accuracy de la validation (courbe orange) et celle de l'entraînement (courbe bleue) démontre la quantité de surajustement. La courbe orange (précision de validation) montre une précision d'approbation exceptionnellement faible par rapport à l'accuracy de l'entraînement. Obtenir un surajustement élevé implique que nous devons régulariser le modèle avec des techniques (Dropout pour notre cas) et recueillir plus d'informations. Le deuxième cas concevable est lorsque l'accuracy de la validation suit vraiment bien l'accuracy de l'entraînement [186]. Ce cas démontre que la capacité du modèle n'est pas suffisamment élevée. Cela nous a fait penser à agrandir le modèle en augmentant le nombre de paramètres. La section suivante nous montre les résultats de la solution proposée pour éliminer le surajustement et obtenir de meilleures performances.

Nous avons introduit la technique de Dropout comme l'une des techniques de régularisation faciles et largement utilisées, le nouveau modèle que nous avons obtenu est comme sur la figure 4-15. De Tensorboard, nous obtenons l'accuracy d'entraînement et de validation :




Figure 4- 17: L'accuracy de l'entraînement et de la validation après le Dropout

À partir de la figure 4-17 ci-dessus, nous pouvons immédiatement voir que le modèle avec Dropout atteint de bonnes performances. Avec le modèle 2, la courbe de validation (orange) suit celle de l'entraînement (bleu), ce qui signifie que le surapprentissage est rapidement minimisé même avec moins de neurones pendant l'apprentissage (l'effet du décrochage). Cet effet peut être vu dans l'accuracy où le pourcentage de bonne classification atteint 60% après 6 époques. Cette précision continue d'augmenter lentement, atteignant 85% après 20 époques. Nous pouvons dire que le moyen le plus simple de limiter le surajustement est d'introduire la technique Dropout. L'emplacement de cette technique (Dropout) peut influencer les résultats, même si nous pouvons l'appliquer pour chaque couche du réseau ou après des couches sélectionnées, nous devons donc essayer différentes combinaisons pour obtenir les meilleurs résultats. De plus, les probabilités de décrochage fixes influencent directement le surajustement. L'écart a été partiellement réduit cependant, il a besoin de plus de régularisation et d'amélioration de la capacité du modèle à généraliser. Pour cela, nous proposerons des solutions d'amélioration pouvant être accompagnée de la technique du dropout. Ces fonctions d'activation pour les réseaux de neurones sont ReLU et ELU. ReLU (Rectified Linear Unit) est la fonction la plus populaire. Elle permet un entraînement plus rapide comparé aux fonctions Sigmoid et Tanh, étant plus légères. ELU (Exponential Linear Unit) : Autre dérivé de la ReLU. Celle-ci va approcher les valeurs moyennes proches de 0, ce qui va

avoir comme impact d'améliorer les performances d'entraînements. Elle utilise exponentiel pour la partie négative et non plus une fonction linéaire.

6. Discussion

Dans cette section, nous discuterons les résultats obtenus dans les trois expériences, Après avoir exécuté chaque modèle séparément et obtenu les résultats pour chacun, nous les avons évalués selon des critères et des métriques connues, ainsi nous présenterons différentes façons d'optimiser et d'améliorer les résultats pour chaque étude. Plusieurs paramètres sont utilisés pour évaluer les performances des modèles de classification et de prédiction. L'accuracy et l'erreur sont quelques-unes des mesures permettant d'évaluer les performances des modèles de classification l'accuracy est le nombre de prédiction correctes sur le nombre total de prédictions réalisées. L'erreur de classification est le nombre relatif d'exemples mal classés, en d'autres termes, le pourcentage de prédictions erronées et incorrectes, Nous avons évoqué précédemment les autres métriques d'évaluation dans le troisième chapitre. Afin de montrer les résultats obtenus pour notre modèle. Le tableau 4-2 illustre les résultats en termes de précision et d'erreur pour chaque expérimentation.

Tableau 4- 2. Les performances avant et après l'amélioration

Expériences	Technique utilisé	Techniques d'optimisation	Résultats
Expérience 1	CNN amélioré	Tensorboard Python	73% avant et 82% après.
Expérience 2	YoloV5 modifié	Ajustement des paramètres des différentes couches	80% avant et 83% après
Expérience 3	CNN amélioré	Dropout ELU	85% avant et >90% après

Les techniques que nous avons utilisées dans ces expérimentations visent à améliorer les résultats des algorithmes proposés, ces techniques sont : utilisation de Tensorboard, exploitation la puissance du code python, les réglages appropriés, bien construire l'algorithme, utilisation des techniques de régularisation et d'activation. Après avoir mené ces expériences, nous avons remarqué une évolution significative des résultats après et avant la solution proposée, où dans la

première expérience le résultat est passé de 73% à 82%, dans la deuxième expérience de 80% à 83% et dans la troisième expérience de 85% à 95%.

En bref, les expériences ont démontré les moyens de construire et d'optimiser des modèles d'apprentissage en profondeur. Nous avons vu à travers la première étude que l'obtention d'excellents résultats est liée au choix des paramètres appropriés qui contrôlent la profondeur, la largeur du modèle, le nombre de couches, leur configuration ainsi que le prétraitement des données et leurs tailles.

À partir de la deuxième étude, nous pouvons conclure que l'identification précoce du surajustement est utile, mais cela ne résout pas le problème. Heureusement, nous avons plus de choix à essayer en plus de Dropout et ELU. Ces autres méthodes peuvent également limiter le surajustement et augmenter l'accuracy et la précision, nous citons : Validation croisée (Cross-validation) : utilisation des données de l'entraînement initiales pour produire de nombreuses divisions de test de train mineures que prévu. Utilisez ces pièces pour régler le modèle [187]. Augmenter la taille de la base de données : entraînement de modèle avec des données supplémentaires peut améliorer les algorithmes pour mieux identifier le signal [188]. L'arrêt précoce (Early stopping) : consiste à arrêter d'apprentissage dès que la perte de validation atteint un certain niveau [189]. Normalisation par lots (Batch normalization) : chaque couche observe les entrées produites par les couches qui la précèdent. Il serait avantageux d'avoir des entrées centrées et réduites pour chaque couche [190]. Global Average Pooling (GAP) : a été proposé pour remplacer la partie perceptron multicouche. L'idée est de générer une carte de caractéristiques pour chaque catégorie correspondante. Au lieu d'ajouter un perceptron après les cartes de caractéristiques, nous prenons la moyenne de chacune d'elles, le résultat est inséré dans la fonction Softmax. Un avantage du GAP par rapport aux couches perceptrons est qu'il n'y a pas de paramètres à entraîner, donc le surapprentissage est évité [191]. Il existe de nombreuses raisons pour lesquelles ce sont des solutions pratiques et efficaces :

- Data-augmentation: aide les algorithmes d'apprentissage automatique à trouver les caractéristiques les plus évidentes qui distinguent une classe d'une autre. Le modèle est donc exposé à davantage de données. Cela lui permet de mieux généraliser.
- Tensorbord: offre la visualisation de différentes métriques telles que la perte, la précision à l'aide de différents graphiques et histogrammes. Cela nous donne une idée de l'ajustement que nous faisons sur les paramètres pour obtenir la menace optimale.

- Code python : on peut utiliser le code python pour trouver le réglage approprié, ces algorithmes sont pilotés par leurs paramètres qui influencent directement le résultat. La solution du réglage des paramètres donne la valeur optimale de chaque paramètre afin d'améliorer la précision du modèle.
- Le Dropout peut être interprété comme un échantillonnage d'un réseau de neurones dans le réseau de neurones complet et mettre à jour uniquement les paramètres du réseau échantillonné. La différence est que ces sous-réseaux partagent des paramètres.
- D'autres voient Dropout comme une forme d'augmentation des données en corrompant artificiellement les entrées dans chaque couche. Cela augmente considérablement le nombre d'exemples que le modèle utilisera lors de l'apprentissage pour aider à se protéger contre le surajustement.
- Une autre interprétation est qu'il s'agit d'une forme de bagging dans laquelle un ensemble de modèles n'est formé que sur un petit sous-ensemble de données.
- Les unités linéaires exponentielles (ELU) résolvent le problème du gradient de fuite avec identité pour les entrées positives.
- ELU améliore l'apprentissage car il a des valeurs négatives qui lui permettent de rapprocher de zéro les activations moyennes de l'unité, ce qui accélère l'apprentissage et conduit à une meilleure précision dans la classification.

Les résultats de ces expériences nous ont fait réfléchir à l'adoption d'un modèle d'apprentissage en profondeur pour créer un système intelligent de détection automatisée des adventices dans les cultures en temps réel afin d'obtenir une pulvérisation localisée de ces mauvaises herbes avec le bon herbicide au lieu de pulvériser toute la surface. L'idée consiste à déployer ce modèle de deep learning entraîné et enregistré sur un Raspberry équipé d'une caméra qui scanne le champ en mouvement pour détecter les mauvaises herbes en temps réel [192]. Le Raspberry envoie un ordre de démarrage à une pompe 12V [193], qui fonctionne en alternance avec d'autres pompes, selon l'espèce de mauvaise herbe détectée. Ce système est également configuré de manière à pouvoir être contrôlé à distance depuis un autre ordinateur ou appareil mobile [194] ; la figure 4-18 montre bien le synoptique de ce système de pulvérisation:




Figure 4- 18:Vue d'ensemble du système de pulvérisation

- **T1, T2 et T3** : Les réservoirs d'herbicide A, B, C dépendent des espèces de mauvaises herbes présentes dans le champ.
- **P1, P2 et P3** : Pompes de l'herbicide A, B, C.

La valeur ajoutée du système que nous avons décrit ci-dessus peut être résumé dans ce qui suit: Ce système contribuera à la préservation de l'environnement. Aussi l'utilisation économique de l'herbicide, identifier rapidement le type de mauvaises herbes et déterminer le type d'herbicide approprié en temps réel, l'efficacité de la pulvérisation des zones touchées, il produira un ensemble de données qui peuvent être utilisées dans le suivi et la prise de décision, il peut être contrôlé à distance. En fin de compte, nous pouvons également élargir la liste des mauvaises herbes indésirables en la reprogrammant après qu'il nous soit apparu clairement que ce système est efficace dans le but recherché.

7. Conclusion

En agriculture, les mauvaises herbes causent des dommages directs à la culture et affectent principalement le potentiel de rendement de la culture. Les méthodes de désherbage manuel et mécanique demandent beaucoup d'énergie et exigent beaucoup de temps et sans pour autant

donner des résultats satisfaisants. Le désherbage chimique reste le meilleur moyen de lutte contre les mauvaises herbes. Les scientifiques et les chercheurs essaient toujours de proposer un modèle efficace pour un système intelligent à même de détecter les mauvaises herbes dans les cultures en temps réel à l'aide de la vision par ordinateur ; ils essaient toujours tous les moyens pour obtenir une bonne performance des algorithmes de deep learning. Dans ce chapitre, nous avons présenté les résultats des expériences publiées dans des revues internationales, dont le but est de proposer des moyens et des solutions d'optimisation et d'amélioration des modèles CNN capable de détecter et d'identifier les espèces de mauvaises herbes. Nous avons proposé de nombreuses techniques qui permettent d'augmenter les résultats obtenus. Ces propositions se sont conclues par une proposition de système intelligent basé sur l'apprentissage en profondeur qui peut être adopté dans la lutte contre ces mauvaises herbes. Le chapitre suivant sera considéré comme une extension de ce chapitre, où nous présenterons d'autres méthodes pouvant être utilisées pour améliorer l'efficacité des modèles d'apprentissage profond. Nous apporterons également une contribution scientifique en termes de modèles d'apprentissage profond qui peuvent être exploités dans le domaine de l'agriculture de précision.

CHAPITRE

V

CHAPITRE V: MODÈLE HYBRIDE DE DEEP ANALYTICS APPLIQUÉ À LA DÉTECTION DES MAUVAISES HERBES

1. Introduction

Le contrôle de mauvaises herbes dans les champs implique l'identification et la caractérisation de type de mauvaise herbe. En tant que tels, les procédés automatisés de détection et de classification des types de mauvaise herbe connus ont d'importantes applications dans ce domaine. Sur la base de l'importance de la classification des mauvaises herbes dans le leur contrôle, les chercheurs ont proposé de nombreux algorithmes pour identifier les mauvaises herbes de culture [195][196]. Des chercheurs ont classé les mauvaises herbes à l'aide de SVM avec un taux de reconnaissance de 98% [116]. D'autres ont utilisé des images pour effectuer les mêmes expériences. Ils ont mis en œuvre le seuil automatique et le contour adaptatif aux cellules de segment, ils ont utilisé la méthode de la plus petite erreur pour les classer, le taux de reconnaissance était de moyenne de 96% [197]. D'autres chercheurs ont utilisé l'algorithme KNN. Cependant, l'algorithme KNN ne gère pas bien les échantillons non équilibrés. Si la capacité d'échantillonnage d'une classe est grande, alors que la capacité d'échantillonnage d'autres classes est petite, des problèmes surviennent. Par exemple, lorsqu'un nouvel échantillon est entré dans le système de diagnostic, il peut en résulter une classe avec une grande capacité d'être dominant dans les K plus proches voisins de cet échantillon. De plus, l'algorithme est coûteux en calcul, car chaque échantillon doit être catégorisé afin de calculer sa distance par rapport à tous les échantillons connus afin d'obtenir ses K voisins les plus proches. Par conséquent, cet algorithme est plus approprié pour des échantillons de données plus importants. Pour les données avec moins d'échantillons, il est plus susceptible de produire des classifications incorrectes. Les expériences ci-dessus sur les mauvaises herbes ont une caractéristique commune. En particulier, que le résultat final soit bon ou mauvais, ils n'utilisent qu'une petite quantité d'images, ou utilisent leur propre base de données pour tester leur identification, les résultats deviennent biaisés [198]. À notre connaissance, il n'existe pas de grandes bases de données publiques de détection et de classification des mauvaises herbes qui se sont propagées dans l'environnement de notre étude, Par exemple, des datasets d'images de mauvaises herbes connues dans notre région. Par conséquent, afin de décrire l'efficacité de l'algorithme proposé de manière juste et objective, nous avons collecté certains ensembles de vraies images de champs prises par des caméras, nous les avons combinées avec des images que nous avons obtenues sur Internet à partir de bases de données publiques. Cet ensemble de données est prétraité, il l'a ensuite transformé en 18000 images (comportant 75 % données d'entraînement et 25% données de test). Dans cet ensemble de données, nous divisons les mauvaises herbes en 4 types différents, à savoir Beta Vulgaris,

Capsella, Chenopodium, Galium Aparine [175]. Ces mauvaises herbes sont les plus courantes dans l'environnement d'étude.

Avec l'amélioration des performances de l'ordinateur, le réseau de neurones convolutifs est devenu plus populaire ces derniers temps, différentes améliorations de l'architecture CNN ont été apportées de 1989 à nos jours. Ces améliorations peuvent être classées en optimisation des paramètres, régularisation, reformulation structurelle, etc. Cependant, il est observé que l'essentiel de l'amélioration des performances de CNN provenait de la restructuration des unités de traitement et de la conception de nouveaux blocs. La plupart des innovations dans les architectures de CNN ont été faites par rapport à la profondeur et à l'exploitation spatiale. Selon le type de modifications architecturales, les CNN peuvent être largement classés en sept classes différentes, à savoir ; exploitation spatiale, profondeur, trajets multiples, largeur, exploitation de la carte des caractéristiques, amplification des canaux, etc. [199], parmi les modèles de CNN qui nous intéressent beaucoup dans cette expérience de détection de mauvaises herbes, nous citons, ResNet [200] et ResNeXt [201].

Bien que le réseau de neurones à convolution profonde (CNN) et les méthodes traditionnelles d'apprentissage automatique aient montré de bons résultats dans la classification des images de mauvaise herbe, ils sont incapables d'exploiter pleinement la relation de dépendance à long terme entre certaines caractéristiques clés des images et des étiquettes d'images. Pour résoudre ce problème, nous avons introduit une machine à vecteur de support linéaire (SVM) [202]. Plus précisément, nous avons combiné un réseau ResNeXt et le SVM afin de proposer le cadre ResNeXt-SVM qui peut approfondir la compréhension du contenu des images, apprendre les caractéristiques structurées des images et commencer l'apprentissage de bout en bout des mégadonnées en analyse d'images de champ de l'agriculture.

Les résultats expérimentaux montrent que par rapport aux autres modèles CNN tels que ResNet et ResNeXt, notre modèle de réseau proposé est plus précis et efficace pour classer les images de mauvaises herbes. La problématique abordée par ce chapitre tourne autour du problème de segmentation d'image d'une mauvaise herbe, le taux de segmentation contrairement à ce qu'offrent les modèles existants diffère d'une étude à l'autre, mais en général c'est difficile d'obtenir un taux très élevé, car il s'agit de détecter parfois de très nombreux objets sur des fonds différents, avec le risque de confondre plusieurs objets distincts avec un seul objet. La structure de ce chapitre est la suivante : la première section passe en revue les méthodes existantes pour améliorer les performances de la prédiction obtenue par un modèle de machine learning. La deuxième section

décrit un algorithme amélioré basé sur le modèle ResNeXt-SVM. La troisième section décrit les résultats expérimentaux ainsi analyse et discute notre approche. Enfin, la dernière section résume la nouveauté et l'utilité de notre approche proposée et suggère des implémentations pour des travaux futurs. Cette contribution a fait objet d'un nouvel article publié récemment dans une revue indexée Scopus [203].

2. Amélioration de la performance de la prédiction obtenue

Comme il a été montré au cours des chapitres précédents, les algorithmes d'apprentissage automatique permettent de construire un modèle prédictif à partir de données historiques et de l'utiliser pour prédire de nouvelles données. Depuis l'avènement de cette technologie jusqu'à aujourd'hui, les scientifiques ont essayé de trouver des moyens de développer le modèle et de rechercher des solutions pour obtenir de meilleures prédictions de « machine learning ».

De nombreuses méthodes sont apparues pour améliorer le deep learning pour obtenir de meilleurs résultats, dans la section suivante nous essaierons d'en parler. Nous les diviserons en quatre familles, à savoir : l'amélioration des données, les méthodes des algorithmes machine learning, les réglages du modèle, les méthodes ensemblistes.

2.1 Amélioration de la performance relative aux données

Il n'y a pas de deep learning sans la présence de données, nous pouvons donc dire que les données sont le carburant du deep learning avec lequel elles atteignent les résultats souhaités, le premier processus à prendre en compte pour obtenir de meilleurs résultats est de prêter attention aux données, car cela donne les gains de performances les plus importants. Les idées de traitement des données sont liées aux : collecte plus de données, la production de nouvelles données, la purification et au filtrage des données, la transformation des données, et, la partie suivante est un détail de ces processus [204].

❶ Collecter plus de données

La plupart des articles scientifiques ont montré que les résultats de deep learning s'améliorent avec plus de données [205]. La quantité de données est l'un des principaux points qui rendent le deep learning si passionnant, comme le montre la figure 5-1 ci-dessous, plus un modèle dispose de données d'entraînement, plus il peut correctement prédire de bons résultats.




Figure 5- 1: L'évolution de la performance de DL avec la quantité de données

Bien que plus de données soient importantes dans le processus d'apprentissage automatique, elles ne conduisent pas toujours à obtenir de meilleurs résultats, parfois cela peut être la cause d'un surapprentissage « Overfitting » [206], donc il faut prendre en compte la question de la quantité et de la qualité en même temps.

② Générer de nouvelles données

Comme nous l'avons vu dans la partie précédente, la quantité de données est un facteur important pour obtenir de meilleures performances. Mais dans de nombreux domaines, cette tâche est difficile, il n'est pas toujours facile d'obtenir plus de données pour plusieurs raisons. Il existe donc une solution alternative, qui consiste à produire plus de données en utilisant des méthodes spécifiques, ces données sont statistiquement proches des données d'origine, alors beaucoup de données peuvent être obtenues et l'apprentissage peut être fait dessus [207].

Les techniques de production des données synthétiques sont trop nombreuses, différent selon le type des données. Si, par exemple, ce sont des images, certaines méthodes peuvent être utilisées comme la génération des versions modifiées de manière aléatoire d'images existantes, si les données sont des vecteurs de nombres, il est possible de créer des versions modifiées aléatoirement de vecteurs existants. Si les données sont du texte, d'autres méthodes peuvent être utilisées. Les méthodes qui peuvent être utilisées sont les suivantes :

- *L'augmentation des données existantes ;*

L'augmentation de données est une technique permettant de créer artificiellement de nouvelles données d'entraînement à partir de données d'entraînement existantes. Cela se fait en appliquant des techniques spécifiques au domaine à des exemples à partir des données d'apprentissage qui créent des exemples d'apprentissage nouveaux et différents.

L'augmentation de données d'image est peut-être le type d'augmentation de données le plus connu et implique la création de versions transformées d'images dans l'ensemble de données d'apprentissage qui appartiennent à la même classe que l'image d'origine.

Les transformations incluent une gamme d'opérations dans le domaine de la manipulation d'images, telles que les décalages, les retournements, les zooms et bien plus encore.

L'objectif est d'étendre l'ensemble de données d'entraînement avec de nouveaux exemples plausibles. Cela signifie que les variations des images d'ensemble d'apprentissages qui sont susceptibles d'être vues par le modèle. Par exemple, un retournement horizontal d'une photo d'un chat peut avoir du sens, car la photo aurait pu être prise depuis la gauche ou la droite. Un retournement vertical de la photo d'un chat n'a pas de sens et ne serait probablement pas approprié étant donné qu'il est très peu probable que le modèle voit une photo d'un chat à l'envers [208].

▪ *Utilisation d'un modèle probabiliste : méthode Monte Carlo ;*

La fonction de cette méthode est d'étudier les limites de confiance statistique dans les analyses de distribution. L'idée de l'analyse Monte-Carlo est la génération d'un grand nombre (par exemple 100 - 1000) d'ensembles de données synthétiques qui sont similaires à l'ensemble de données expérimentales, mais chacun avec un bruit aléatoire normalement distribué différemment. Chacun de ces nouveaux ensembles de données est analysé et les distributions sont stockées. L'ensemble de distributions résultant peut alors être étudié, point par point, les contours de moyenne et de probabilité peuvent être calculés [209].

En substance, les statistiques de Monte-Carlo permettent de construire une fonction de distribution de probabilité, permettent aussi d'étudier dans quelle mesure le bruit des données est traduit dans la distribution. En conséquence, la procédure de Monte-Carlo peut être utile pour étudier quelles caractéristiques de la distribution sont le résultat du bruit dans les données et quelles caractéristiques sont essentielles pour décrire les

données. Deux caractéristiques principales sont mises en évidence dans la mise en œuvre de SEDFIT : les contours de confiance de la distribution (c'est-à-dire sa forme) et l'intégrale (valeurs moyennes en poids et concentrations de charge à travers un pic ou dans une région) [210].

- *Utilisation d'une technique du deep learning : Variational Autoencoder (VAE) ou Generative adversarial network (GAN) ; [211]*

VAE est une méthode non supervisée où l'encodeur compresse l'ensemble de données d'origine dans une structure plus compacte et transmet les données au décodeur. Ensuite, le décodeur génère une sortie qui est une représentation de l'ensemble de données d'origine. Le système est entraîné en optimisant la corrélation entre les données d'entrée et de sortie [212].

La figure 5-2 présente le processus de la production des nouvelles données en décodant des points échantillonnés au hasard dans l'espace latent. La qualité et la pertinence des données générées dépendent de la régularité de l'espace latent.




Figure 5- 2: La production de nouvelles données en décodant des points échantillonnés

Dans le modèle GAN (Generative Adversarial Networks), deux réseaux, générateur et discriminateur, entraînent le modèle de manière itérative. Comme indiqué sur la figure 5-3, le générateur prend des données d'échantillon aléatoire et génère un ensemble de données synthétiques. Le discriminateur compare les données générées synthétiquement avec un ensemble de données réel en fonction des conditions définies auparavant [213].

Le principe des GAN est de créer des informations sans aucune préparation, pour la plupart des images. Tout comme le modèle en dessous, il crée un zèbre à partir d'un poney. Dans l'apprentissage de la fortification, cela encourage un robot à s'adapter beaucoup plus rapidement [214].

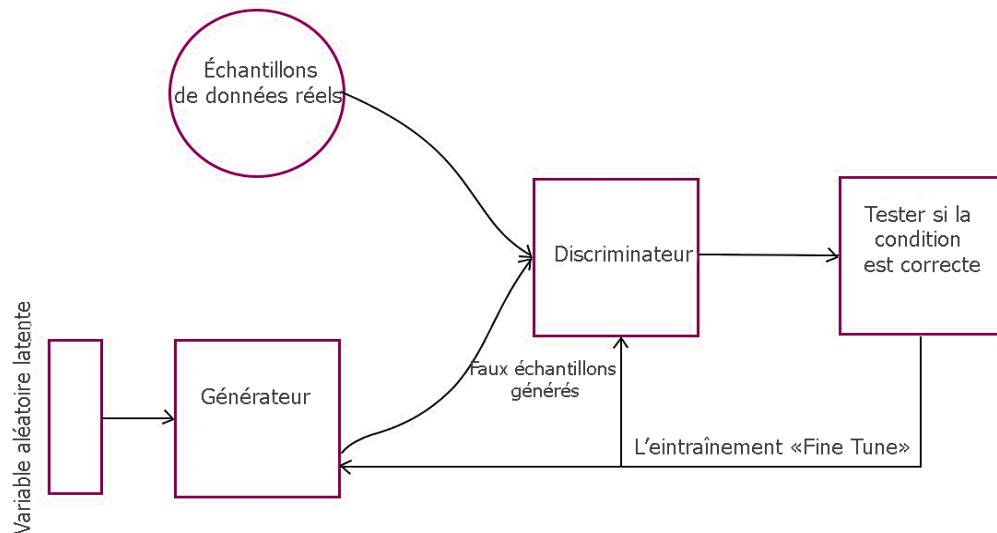


Figure 5- 3: Fonctionnement du GAN

③ Nettoyer les données

Le nettoyage des données désigne le processus d'identification de la partie incorrecte, incomplète, inexacte, non pertinente ou manquante des données qui peut avoir un impact négatif sur un modèle prédictif, puis de les modifier, les remplacer ou les supprimer selon la nécessité. Le nettoyage des données est considéré comme un élément fondamental de l'apprentissage automatique.

Il existe de nombreux types d'erreurs dans un ensemble de données, bien que certaines des erreurs les plus simples incluent des colonnes qui ne contiennent pas beaucoup d'informations et des lignes dupliquées [215].

④ Rééchantillonner les données

De manière générale, une méthode de rééchantillonnage est un outil consistant à tirer à plusieurs reprises des échantillons d'un ensemble de données et à calculer des statistiques et des métriques sur chacun de ces échantillons afin d'obtenir plus d'informations. Cette étape est très importante dans le cas où les données sont déséquilibrées. Sur-

échantillonnage (Over-sampling) ou sous-échantillonnage (under-sampling) sont les techniques permettant de représenter au mieux l'ensemble de données [216].

Ce qui rend nécessaire l'utilisation de cette méthode de rééchantillonnage c'est : « Random Chance ». Chaque fois que nous tirons un échantillon d'une population et calculons une statistique, le paramètre estimé peut être aussi proche de la valeur réelle de la population, uniquement en raison du hasard, nous n'avons donc aucune information sur la confiance de nos conclusions et notre prédiction sera douteuse [217]. C'est pourquoi nous utilisons « Bootstrapping », en tirant plusieurs échantillons de notre échantillon d'origine (rééchantillonnage), nous pouvons explorer les différentes combinaisons qui pourraient résulter en premier lieu, en calculant les erreurs types et les intervalles de confiance, ce qui nous donne une gamme cohérente de valeurs pour estimer le vrai paramètre de population.

⑤ Redimensionner les variables (Features scaling)

Features scaling est une méthode utilisée pour normaliser la plage de variables indépendantes ou de caractéristiques des données. Dans le traitement des données, il est généralement effectué lors de l'étape de prétraitement des données [218]. Si on a plusieurs variables indépendantes comme l'âge, le salaire et la taille ; avec leur plage de (18 à 100 ans), de (25 000 à 75 000 Dirhams) et (1 à 2 mètres) respectivement, la mise à l'échelle des caractéristiques les aiderait tous à être dans la même plage, par exemple, centrés autour de 0 ou dans la plage (0,1) selon la technique de mise à l'échelle. Les deux techniques de mise à l'échelle les plus courantes sur l'ensemble de données sont la normalisation et la standardisation [219][220] :

▪ Normalisation ;

Également appelée mise à l'échelle min-max ou normalisation min-max, il s'agit de la méthode la plus simple et consiste à redimensionner la plage de caractéristiques pour mettre à l'échelle la plage dans [0, 1]. La formule générale de normalisation est donnée par l'équation (5-1) :

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (\text{Éq. 5-1})$$

Ici, max(x) et min(x) sont respectivement les valeurs: maximale et minimale de la caractéristique.

Nous pouvons également effectuer une normalisation sur différents intervalles, par exemple choisir d'avoir la variable située dans n'importe quel intervalle [a, b], a et b

étant des nombres réels. Pour redimensionner une plage entre un ensemble arbitraire de valeurs [a, b], la formule devient (Éq. 5-2) :

$$x' = a + \frac{(x - \min(x))(b - a)}{\max(x) - \min(x)} \quad (\text{Éq. 5-2})$$

▪ *Standardisation* ;

La standardisation est une autre technique de mise à l'échelle où les valeurs sont centrées autour de la moyenne avec un écart type unitaire. Cela signifie que la moyenne de l'attribut devient zéro et que la distribution résultante a un écart type unitaire. Voici la formule de standardisation (Éq. 5-3) :

$$x' = \frac{x - \mu}{\sigma} \quad (\text{Éq. 5-3})$$

Ici, σ est l'écart type des valeurs des caractéristiques. Notez que dans ce cas, les valeurs ne sont pas limitées à une plage particulière. μ est la moyenne des valeurs des caractéristiques.

Ces techniques sont utilisées pour élever le niveau de performance des algorithmes qui utilisent les entrées pondérées, parmi les algorithmes qui considèrent l'utilisation de cette technique nécessaire, nous mentionnons :

- L'analyse en composantes principales (ACP ou PCA en anglais pour Principal Component Analysis) ;
- K-means (ou K-moyennes) ;
- K plus proches voisins (ou K-Nearest Neighbors kNN) ;
- Le gradient descent.

⑥ **Sélectionner les caractéristiques**

La sélection des caractéristiques en anglais "Features Selection" est le processus qui sélectionne automatiquement ou manuellement les caractéristiques qui contribuent le plus à la variable de prédiction. Le fait d'avoir des caractéristiques non pertinentes dans les données peut diminuer la précision des modèles d'apprentissage automatique [221]. Les principales raisons d'utiliser la sélection de fonctionnalités sont :

- Il permet à l'algorithme d'apprentissage automatique de s'entraîner plus rapidement.
- Il réduit la complexité d'un modèle et le rend plus facile à interpréter.
- Il améliore la précision d'un modèle si le bon sous-ensemble est choisi.

- Il réduit le surapprentissage « Overfitting ».

Les méthodes courantes de « Features selection » sont [222] :

- *Sélection univariée (Univariate Selection)* ;

Les tests statistiques peuvent aider à sélectionner les entités indépendantes qui ont la relation la plus forte avec l'entité cible dans votre jeu de données. Par exemple, le test du chi-squared.

- *Importance de la fonctionnalité (Feature Importance)* ;

« Feature Importance » donne un score pour chaque caractéristique de données. Plus le score est élevé, plus cette caractéristique est importante ou pertinente pour votre caractéristique cible. « Feature Importance » est une classe intégrée fournie avec des classificateurs basés sur des arbres « Tree » tels que : les classificateurs de forêts aléatoires et les classificateurs d'arbres supplémentaires (Random Forest Classifiers) et (Extra Tree Classifiers).

- *Matrice de corrélation (Correlation Matrix Heatmap)* ;

La corrélation montre comment les entités sont liées les unes aux autres ou à l'entité cible. La corrélation peut être positive (une augmentation d'une valeur de la caractéristique augmente la valeur de la variable cible) ou négative (une augmentation d'une valeur de la caractéristique diminue la valeur de la variable cible).

⑦ Extraire les caractéristiques (Features engineering)

« Features engineering » fait référence à un processus de sélection et de transformation de variables/caractéristiques dans l'ensemble de données lors de la création d'un modèle prédictif à l'aide de l'apprentissage automatique. Par conséquent, il faut extraire les fonctionnalités de l'ensemble de données brutes collectées avant d'entraîner les données dans des algorithmes d'apprentissage automatique. Sinon, il sera difficile d'obtenir de bonnes informations sur vos données [223].

Cette méthode a deux objectifs. La première consiste à préparer l'ensemble de données d'entrée approprié, compatible avec les exigences de l'algorithme d'apprentissage automatique. Le second est d'améliorer les performances des modèles d'apprentissage automatique.

③ Transformer les données

Les algorithmes d'apprentissage automatique tels que la régression linéaire et Gaussian Naive Bayes supposent que les variables numériques ont une distribution de probabilité gaussienne.

Les données peuvent ne pas avoir une distribution gaussienne et à la place avoir une distribution de type gaussienne (par exemple, presque gaussienne mais avec des valeurs aberrantes ou une asymétrie) ou une distribution totalement différente (par exemple, exponentielle) [224].

En tant que tel, il est possible d'obtenir de meilleures performances sur un large éventail d'algorithmes d'apprentissage automatique en transformant les variables d'entrée et/ou de sortie pour avoir une distribution gaussienne ou plus gaussienne. Les transformations de puissance telles que la transformation Box-Cox et la transformation Yeo-Johnson fournissent un moyen automatique d'effectuer ces transformations sur les données et sont fournies dans la bibliothèque d'apprentissage machine Python scikit-learn [225].

⑨ Clustering

Le clustering peut être considéré comme le problème d'apprentissage non supervisé le plus important ; ainsi, comme tout autre problème de ce genre, il s'agit de trouver une structure dans une collection de données non étiquetées. Une définition vague du clustering pourrait être « le processus d'organisation d'objets en groupes dont les membres sont similaires d'une manière ou d'une autre ». Un cluster est donc un ensemble d'objets « similaires » entre eux et « dissemblables » aux objets appartenant à d'autres clusters [226].

L'objectif du clustering est de déterminer le regroupement interne dans un ensemble de données non étiquetées. Mais comment décider ce qui constitue un bon clustering ? On peut montrer qu'il n'y a pas de critère absolu de « meilleur » qui serait indépendant de l'objectif final du clustering. Par conséquent, c'est l'utilisateur qui doit fournir ce critère, de manière à ce que le résultat du regroupement corresponde à ses besoins.

2.2 Amélioration de la performance basée sur les méthodes d'exploitation

Il existe plusieurs algorithmes ML possibles et plusieurs “machine learning models” le choix du bon algorithme d'apprentissage automatique dépend de nombreux facteurs tels que problème traité et le type de sortie que vous souhaitez, le type et la taille des données, le temps de calcul disponible, le nombre des attributs, les ressources de calcul et de stockage, etc. Pour choisir un

modèle prédictif après avoir choisi le contexte approprié, il est nécessaire d'essayer un nombre de modèles jusqu'à trouver le bon modèle qui donne de bons résultats [227]. Il existe également plusieurs techniques qui peuvent être appliquées à l'algorithme, notamment :

❶ Méthode de rééchantillonnage

La méthode de rééchantillonnage est un outil nécessaire pour mieux exploiter les données d'apprentissage. L'apprentissage des paramètres d'une fonction de prédiction sur des données et de faire le test sur les mêmes données est une erreur méthodologique : un modèle qui ne répéterait que les étiquettes des échantillons qu'il vient de voir aurait un score parfait, mais ne prédirait rien utile sur des données non publiées [228]. La validation croisée « cross-validation » est la technique la plus efficace pour effectuer cette tâche. Dont les données sont divisées en des ensembles pour l'apprentissage, la validation et les tests. Pour estimer les performances du modèle, nous utilisons souvent certaines des données pour l'entraînement et en conservons une partie pour les tests, alors les performances du modèle sur les données de test sont représentatives [229].

❷ Métrique d'évaluation

L'évaluation des performances de l'algorithme de ML est une partie essentielle de tout projet de ML. Nous ne pouvons pas dire si un modèle est bon ou non si nous ne le jugeons pas en utilisant l'une des métriques d'évaluation distinctes qui capte le mieux les exigences du problème. Le modèle peut donner des résultats satisfaisants lorsqu'il est évalué à l'aide d'une métrique, par exemple `precision_score` (`Accuracy_score`), mais peut donner des résultats faibles lorsqu'il est évalué par rapport à d'autres métriques telles que `Logarithmic_loss` ou toute autre métrique de ce type. La plupart du temps, nous utilisons la précision et l'accuracy pour mesurer les performances de nos modèles, mais cela ne suffit pas pour vraiment juger le modèle [230]. Voici quelques métriques qui peuvent être utilisées pour juger un modèle de ML :

- Classement de précision (`Classification Accuracy`)
- Perte logarithmique (`Logarithmic Loss`)
- Matrice de confusion (`Confusion Matrix`)
- Aire sous la courbe (`Area under Curve`)
- Score F1
- Erreur absolue moyenne (`Mean Absolute Error`)
- Erreur quadratique moyenne (`Mean Squared Error`)

③ Performance référentielle

L'une des méthodes pour mieux évaluer et comparer les algorithmes de ML d'apprentissage automatique est le Baseline, il s'appuie sur la création d'une performance de base sur un problème de modélisation prédictive défini comme un modèle simple utilisé comme un point de référence. Cette Baseline fournit un point de comparaison pour les méthodes plus avancées sujet de l'évaluation plus tard [231]. Les deux algorithmes de Baseline les plus couramment utilisés sont :

- **Algorithme aléatoire:** L'algorithme de prédiction aléatoire prédit un résultat aléatoire tel qu'observé dans les données d'apprentissage. C'est peut-être l'algorithme le plus simple à mettre en œuvre. Cela nécessite que vous stockiez toutes les valeurs de résultat distinctes dans les données d'entraînement, ce qui peut être important pour les problèmes de régression avec de nombreuses valeurs distinctes.
- **Algorithme zero-rule :** L'algorithme de règle zéro (Zero-rule) est une meilleure base de référence que l'algorithme aléatoire. Il utilise plus d'informations sur un problème donné pour créer une règle afin de faire des prédictions. Cette règle est différente selon le type de problème.

④ Test de quelques algorithmes linéaires

Ces types des algorithmes sont les plus connus et bien compris en statistiques et en apprentissage automatique, faciles à construire et à entraîner rapidement.

Dans le cas où ces algorithmes linéaires donnent des résultats prédictifs importants, elles doivent être privilégiées, car elles sont plus faciles à améliorer ou à modifier. Le processus d'évaluation est toujours important pour déterminer les algorithmes linéaires les plus efficaces et améliorer les algorithmes s'ils sont faibles [232].

⑤ Test de quelques algorithmes non-linéaires

Ce type d'algorithme diffère des autres, car il a besoin de beaucoup de données pour bien fonctionner et donner de bons résultats, il est plus complexe, mais donne de bons résultats dans la plupart des cas. Son évaluation est également un élément essentiel pour connaître le degré d'apprentissage et faire des améliorations si nécessaires [233].

⑥ Configuration standard

Chaque algorithme, quel que soit son type, a besoin de paramètres de base pour commencer à apprendre et à prédire. À ce stade, rien n'est modifié dans la configuration de l'algorithme, mais nous devons connaître les paramètres afin de pouvoir les modifier pour obtenir de meilleurs résultats et de pouvoir résoudre le problème.

2.3 Amélioration de la performance issue des réglages du modèle

Les algorithmes de machine learning sont pilotés par des paramètres. Ces paramètres influencent majoritairement le résultat du processus d'apprentissage. L'objectif du réglage des paramètres est de trouver la valeur optimale pour chaque paramètre afin d'améliorer la précision du modèle [234]. Pour régler ces paramètres, vous devez avoir une bonne compréhension de ces significations et de leur impact individuel sur le modèle. Vous pouvez répéter ce processus avec un certain nombre de modèles performants.

Par exemple : dans un algorithme de « random forest », nous avons divers paramètres comme `max_features`, `number_trees`, `random_state`, `oob_score` et autres [235]. L'optimisation intuitive de ces valeurs de paramètres se traduira par des modèles meilleurs et plus précis. Concernant un CNN, les paramètres à définir sont : nombre, taille, déplacement des filtres, choix de la méthode de Pooling, choix du nombre de couches de neurones, nombre de neurones par couches, etc. [236].

① Diagnostics des algorithmes

L'utilisation de la courbe d'apprentissage est un moyen pour diagnostiquer un modèle de machine learning, cette courbe est un graphique des performances d'apprentissage d'un modèle au fil de l'expérience ou du temps. Il s'agit d'un outil de diagnostic largement utilisé dans l'apprentissage automatique pour les algorithmes qui apprennent de manière incrémentielle à partir d'un ensemble de données d'entraînement. Le modèle peut être évalué sur l'ensemble de données d'entraînement et sur un ensemble de données de validation après chaque mise à jour pendant l'entraînement et des tracés des performances mesurées peuvent être créés pour montrer les courbes d'apprentissage.

L'examen des courbes d'apprentissage des modèles pendant l'apprentissage peut être utilisé pour diagnostiquer des problèmes d'apprentissage, tels qu'un modèle sous-adapté ou surajusté, ainsi que pour déterminer si les ensembles de données d'apprentissage et de validation sont suffisamment représentatifs [237]. Les courbes d'apprentissage sont largement utilisées dans l'apprentissage automatique pour les algorithmes qui apprennent

(optimisent leurs paramètres internes) de manière incrémentielle au fil du temps, tels que les réseaux de neurones.

La métrique utilisée pour évaluer l'apprentissage pourrait être maximisée, ce qui signifie que de meilleurs scores (plus grands nombres) indiquent plus d'apprentissage. Nous donnons ici un exemple de précision de classification. Il est plus courant d'utiliser un score qui minimise, comme une perte ou une erreur, où de meilleurs scores (chiffres plus petits)[238].

② Utilisation de la configuration citée dans la littérature

Le moyen le plus simple et le plus efficace pour commencer la configuration d'un modèle machine learning consiste à s'appuyer sur les paramètres cités dans la littérature, qui ont déjà été testés et se sont avérés efficaces pour un problème particulier. Ces paramètres peuvent donc servir de point de départ pour configurer un modèle performant.

③ Optimisation des hyperparamètres

Les modèles d'apprentissage automatique ont des hyperparamètres. Ces hyperparamètres sont des points de choix ou de configuration qui permettent de personnaliser un modèle d'apprentissage automatique pour une tâche ou un ensemble de données spécifique. Les paramètres sont différents des hyperparamètres. Les paramètres sont appris automatiquement ; les hyperparamètres sont définis manuellement pour aider à guider le processus d'apprentissage.

Il est souvent nécessaire de rechercher un ensemble d'hyperparamètres qui se traduisent par les meilleures performances d'un modèle sur un ensemble de données. C'est ce qu'on appelle l'optimisation des hyperparamètres, le réglage des hyperparamètres ou la recherche des hyperparamètres [239].

Une gamme d'algorithmes d'optimisation différents peut être utilisée, bien que deux des méthodes les plus simples et les plus courantes soient la recherche aléatoire et la recherche par grille.

Recherche aléatoire. Définissez un espace de recherche en tant que domaine délimité de valeurs d'hyperparamètres et échantillonnez au hasard des points dans ce domaine.

Recherche de grille. Définissez un espace de recherche en tant que grille de valeurs d'hyperparamètres et évaluez chaque position dans la grille.

2.4 Amélioration de la performance tirée des méthodes ensemblistes

L'une des méthodes utilisées pour améliorer les performances des modèles machine learning consiste à combiner un ensemble de prédictions provenant de plusieurs modèles de ML. Aussi différents modèles peuvent être combinés, chacun avec des résultats différents sur un problème, chaque modèle peut être spécialisé dans un processus particulier ou dans une partie particulière de l'apprentissage automatique [240].

❶ Fusionner les prédictions de plusieurs modèles

Un élément clé de l'amélioration des performances consiste à combiner les prédictions de plusieurs modèles. C'est par la combinaison des prédictions que l'on obtient le bénéfice de la méthode d'apprentissage d'ensemble, à savoir une meilleure performance prédictive.

La manière dont les prédictions sont combinées dépend des modèles qui font des prédictions et du type de problème de prédiction [241]. Par exemple, la forme des prédictions faites par les modèles correspondra au type de problème de prédiction, comme la régression pour prédire les nombres et la classification pour prédire les étiquettes de classe. De plus, certains types de modèles peuvent uniquement prédire une étiquette de classe ou une distribution de probabilité de classe, tandis que d'autres peuvent prendre en charge les deux pour une tâche de classification.

❷ Fusionner les prédictions obtenues sur différentes représentations de données

Au cours de ce processus, un ensemble de représentations de données est créé après le processus d'extraction des caractéristiques (Features extraction) l'apprentissage est effectué sur les représentations de données par un modèle pour chaque représentation. Cette méthode nous permet d'obtenir des résultats multiples pour le problème de l'étude en fonction de la multiplicité des représentations de données, le résultat final est obtenu après la combinaison des prédictions pour obtenir un résultat de prédiction de performance de plus [242].

❸ Fusionner les prédictions obtenues sur différents échantillons de données(Bagging)

Cette technique est utile à la fois pour la régression et la classification statistique. Bagging est utilisé avec les arbres de décision, où il augmente considérablement la stabilité des modèles en améliorant la précision et en réduisant la variance, ce qui élimine le défi du surajustement (Overfitting) [243][244].

Comme montré sur la figure 5-4, le Bagging est composé de deux parties : l'agrégation et l'amorçage (Aggregation and Bootstrapping). Le Bootstrapping est une méthode d'échantillonnage, où un échantillon est choisi dans un ensemble, en utilisant la méthode de remplacement. L'algorithme d'apprentissage est ensuite exécuté sur les échantillons sélectionnés. La technique de Bootstrapping utilise un échantillonnage avec remise pour rendre la procédure de sélection complètement aléatoire. Lorsqu'un échantillon est sélectionné sans remise, les sélections ultérieures de variables dépendent toujours des sélections précédentes, ce qui rend les critères non aléatoires.

Les prédictions du modèle sont agrégées pour les combiner pour que la prédiction finale prenne en compte tous les résultats possibles [245]. L'agrégation peut être effectuée sur la base du nombre total de résultats ou de la probabilité de prédictions dérivées de l'amorçage de chaque modèle de la procédure.

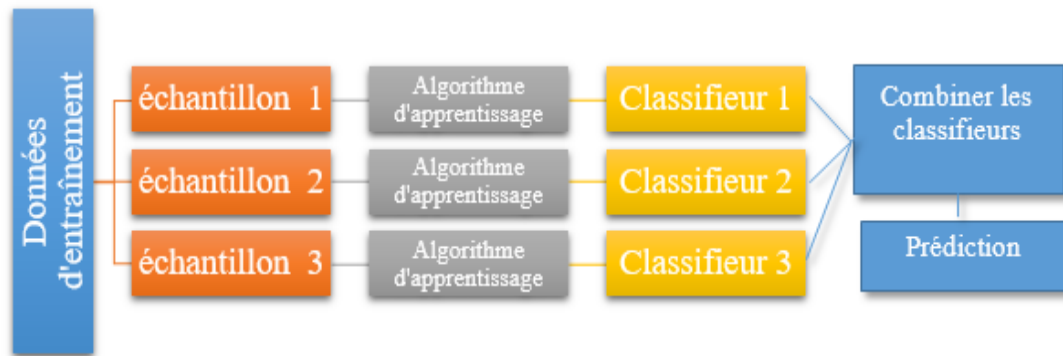


Figure 5- 4: Le fonctionnement de la méthode Bagging

④ Stacking

La généralisation empilée ou « empilement » (stacking) est un algorithme d'apprentissage automatique d'ensemble. Cela implique de combiner les prédictions de plusieurs modèles d'apprentissage automatique sur le même ensemble de données, comme le bagging.

L'architecture d'un modèle d'empilement implique deux ou plusieurs modèles de base, souvent appelés modèles de niveau 0 et un méta-modèle qui combine les prédictions des modèles de base, appelé modèle de niveau 1. Modèles de niveau 0 (Base-Models) : Les modèles s'adaptent aux données d'entraînement et dont les prédictions sont compilées. Modèle de niveau 1 (Méta-modèle) : modèle qui apprend à combiner au mieux les prédictions des modèles de base. En bref il s'agit de prédire quels sont les meilleurs modèles et de les pondérer [246]. Ce processus peut être répété plusieurs fois.

3. Approche proposée : Modèle hybride ResNeXt-SVM

Parmi les moyens d'amélioration de la performance dont nous avons parlé ci-dessus, nous avons essayée de combiner un ensemble de ces méthodes et de proposer un modèle hybride utilisable dans le domaine de l'agriculture. Nous avons également mené un certain nombre d'opérations liées à l'amélioration des performances du modèle combiné, notamment les moyens liés au paramétrage du modèle et à la préparation des données, diagnostics de l'algorithme, etc.

Un certain nombre d'études impliquant des approches de deep learning ont revendiqué des performances de pointe dans un nombre considérable de tâches. Ceux-ci incluent, sans s'y limiter, la classification des images [247], le traitement du langage naturel [248], la reconnaissance vocale [249] et la classification de texte [250]. Les modèles utilisés dans lesdites tâches utilisent la fonction Softmax au niveau de la couche de classification. Cependant, des études [251] [252] ont pré-développé des solutions qui combinent SVM avec d'autres modèles, ce qui nous a donné l'idée de rechercher des solutions similaires et plus efficaces. Les études susmentionnées ont affirmé que l'utilisation de SVM dans une architecture de réseau de neurones artificiels (ANN) produit des résultats relativement meilleurs que l'utilisation de la fonction Softmax conventionnelle [251]. Bien sûr, un inconvénient à cette approche est la restriction à la classification binaire. Comme SVM vise à déterminer l'hyperplan optimal séparant deux classes dans un ensemble de données, un cas multinomial est apparemment ignoré. Avec l'utilisation de SVM dans une classification multinomiale, le cas devient un contre tous, dans lequel la classe positive représente la classe avec le score le plus élevé, tandis que le reste représente la classe négative.

Les applications de l'apprentissage profond en agriculture sont réparties dans plusieurs domaines, les plus populaires étant l'identification des mauvaises herbes, la classification de la couverture végétale, la reconnaissance des plantes, le comptage des fruits et la classification des types de cultures. Les modèles de deep learning se sont multipliés et diversifiés dans la plantation de cultures, les CNN (Convolutional Neural Networks) ont pris la plus grande part, ses modèles dérivés tels que le ResNeXt ont été utilisés dans ce domaine et se sont avérés utiles [253]. SVM est aussi présent dans ces processus liés à la détection des mauvaises herbes avec de bons résultats. En examinant les sources de données utilisées pour former le modèle d'apprentissage pour chaque étude faite dans ce domaine, ils ont principalement utilisé de grands ensembles de données d'images, contenant dans certains cas des milliers d'images. Certaines de ces images proviennent de sources bien connues et accessibles au public telles que PlantVillage, LifeCLEF, MalayaKew

et UC Merced [153]. En revanche, les auteurs en ont produit d'autres pour leurs besoins de recherche.

Comme montré dans les parties précédentes, la plupart des travaux de recherche ont utilisé des architectures CNN pour créer des modèles de deep learning qui détectent les mauvaises herbes. En outre, ils les ont comparés à d'autres modèles en termes de précision et d'erreur. D'autres critères de comparaison ont montré qu'il y a toujours un besoin d'un modèle plus solide en termes de temps d'apprentissage et de précision. Toutes les informations ci-dessous ainsi les résultats obtenus montrent les raisons de choix et pourquoi ces deux modèles ResNeXt et SVM ont été choisis pour les assembler, ainsi expliquent l'approche que nous avons proposée comme alternative aux méthodes traditionnelles.

3.1 Méthodes et outils

Dans cette étude, nous avons utilisé un ensemble de techniques et de méthodes qui ont une relation directe avec le deep learning, où nous avons utilisé les bibliothèques de Keras et TensorFlow pour Python afin de construire et entraîner notre modèle, nous avons utilisé Tensorboard pour évaluer ses performances, nous avons utilisé un ensemble de données pour mener l'apprentissage [254]. Nous discuterons de cette approche qui combine ResNeXt et SVM afin d'obtenir un meilleur résultat.

3.2 Dataset

L'ensemble de données est l'un des facteurs importants affectant la qualité des modèles d'entraînement et chaque fois que nous avons un grand ensemble de données bien préparé, nous avons une précision d'entraînement élevée [203]. L'ensemble de données utilisé lors de cette expérience est un ensemble de données que nous avons précédemment utilisé lors d'une étude sur la détection d'objets qui identifie les mauvaises herbes à l'aide de CNN [175] (figure 5-5). Nous avons ajouté d'autres images du même type obtenues à partir de datasets d'images publiques sur internet, nous utilisons également des images synthétiques.

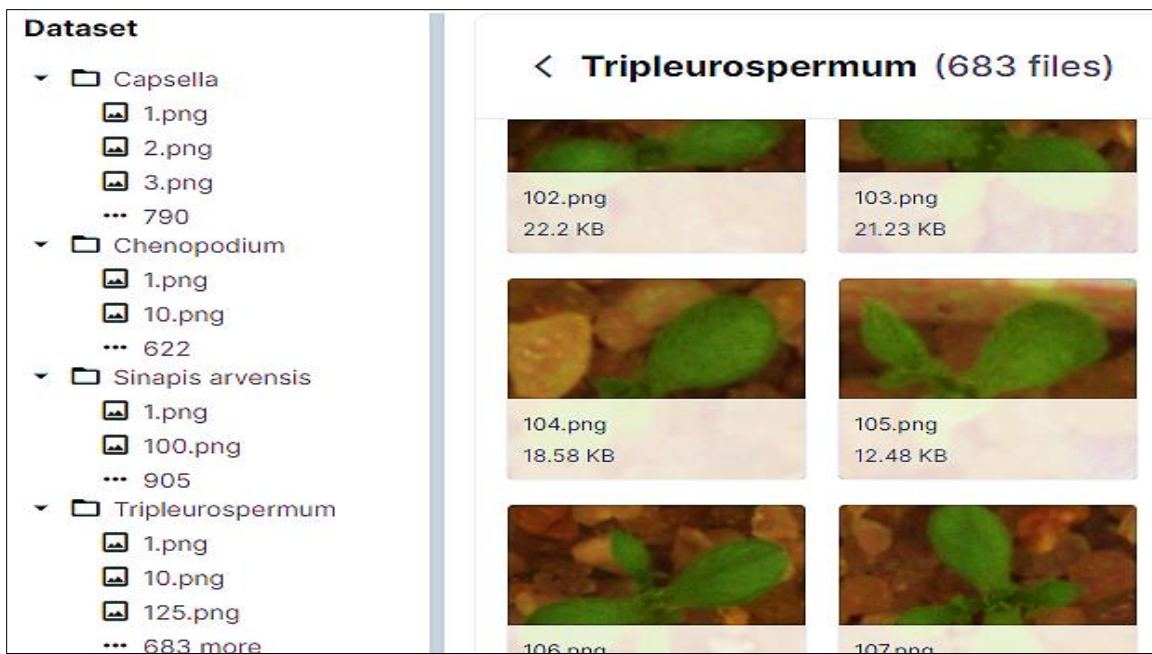


Figure 5- 5: Le jeu de données utilisé dans notre expérience

Selon le rapport scientifique DeepWeeds [255], Olsen a confirmé que nous avons besoin de plus de 17509 images pour obtenir des résultats plus précis, nous avons donc essayé d'obtenir ce nombre d'images pour découvrir la capacité réelle de notre modèle. Le dataset contient 16000 images de quatre types de mauvaises herbes ; ces images sont collectées dans des champs de blé avec un appareil photo Canon professionnel EOS 700D. Cela offre de grands ensembles de données de différentes espèces destinées à la communauté scientifique pour atteindre les objectifs de la science des données. Nous avons ajouté des images du même type d'herbes proviennent du dataset public publié sur la plateforme Kaggle. Nous avons apporté les opérations de prétraitement et d'augmentation des données que nous avons vues au chapitre 4 pour avoir plus d'images appartenant à quatre classes différentes.

3.3 Réseau de neurones ResNeXt

ResNeXt hérité de ResNet, VGG et Inception, proposé par Xie et al. [256], ResNeXt inclut des raccourcis du bloc précédent au bloc suivant, empilant les couches et adaptant la stratégie de division-transformation-fusion (Split-transform-merge). Pour bien comprendre comment fonctionne Resnext, nous devons savoir comment fonctionnent ResNet, VGG et Inception. ResNet se caractérise par l'introduction d'un raccourci de la couche précédente à la couche suivante, VGG : tirer parti des couches répétées pour créer un modèle d'architecture approfondie, Inception repose sur le principe de « Split-transform-merge » pour diviser l'entrée en plusieurs blocs et

fusionner des blocs plus tard. Nous concluons de tout cela que le principe de ResNeXt est d'empiler les mêmes blocs de topologie.

Au sein du bloc résiduel, les hyperparamètres (largeur et tailles de filtre) sont partagés. L'architecture de base de ResNeXt est définie par la règle ; si les blocs produisent des cartes spatiales de même dimension, ils partagent le même ensemble d'hyperparamètres et si la carte spatiale est sous-échantillonnée d'un facteur 2, la largeur du bloc est multipliée par un facteur 2. Cela le rend structuré avec le bloc de construction montrée sur la figure 5-6.

stage	output	ResNet-50	ResNeXt-50 (32×4d)
conv1	112×112	7×7, 64, stride 2	7×7, 64, stride 2
		3×3 max pool, stride 2	3×3 max pool, stride 2
conv2	56×56	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128, C=32 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3	28×28	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256, C=32 \\ 1 \times 1, 512 \end{bmatrix} \times 4$
conv4	14×14	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512, C=32 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$
conv5	7×7	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 1024 \\ 3 \times 3, 1024, C=32 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	global average pool 1000-d fc, softmax	global average pool 1000-d fc, softmax
# params.		25.5×10^6	25.0×10^6
FLOPs		4.1×10^9	4.2×10^9

Figure 5- 6: Une vue comparative entre les paramètres de ResNet et ceux de ResNeXt

La cardinalité est introduite par les auteurs, cela signifie la taille de l'ensemble des transformations. Reportons-nous à la figure 5-7, l'architecture comprend 8 blocs de topologie identiques, la valeur de cardinalité est donc de 8. En raison de l'utilisation de la même topologie, moins de paramètres sont requis tandis que davantage de couches sont ajoutées à cette architecture.

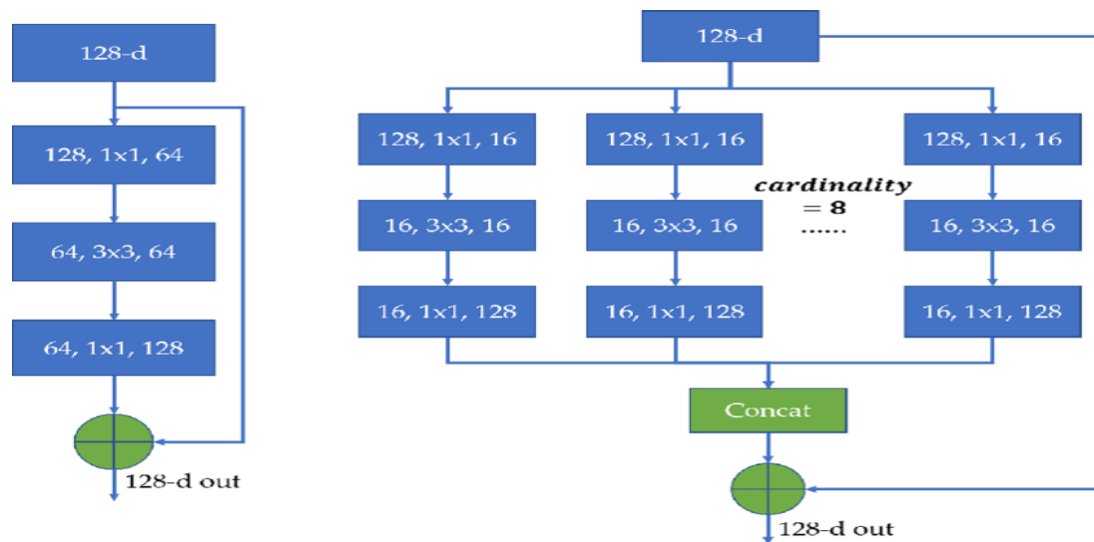


Figure 5- 7: À gauche : Architecture de ResNet et à droite : Architecture de ResNeXt

Il existe de nombreuses variantes de l'architecture ResNeXt, c'est-à-dire le même concept, mais avec un nombre de couches différentes et paramètres différents. ImageNet a été utilisé pour montrer l'amélioration de la précision lorsque la cardinalité est prise en compte plutôt que la largeur/profondeur, la figure 5-8 suivante compare ResNeXt50 et ResNeXt 101 avec de différents paramètres [256][257].

	setting	top-1 error (%)	5K-way classification		1K-way classification	
			top-1	top-5	top-1	top-5
ResNet-50	1 × 64d	23.9	45.5	19.4	27.1	8.2
ResNeXt-50	2 × 40d	23.0	42.3	16.8	24.4	6.6
ResNeXt-50	4 × 24d	22.6				
ResNeXt-50	8 × 14d	22.3				
ResNeXt-50	32 × 4d	22.2				
ResNet-101	1 × 64d	22.0	42.4	16.9	24.2	6.8
ResNeXt-101	2 × 40d	21.7	40.1	15.1	22.2	5.7
ResNeXt-101	4 × 24d	21.4				
ResNeXt-101	8 × 14d	21.3				
ResNeXt-101	32 × 4d	21.2				

Figure 5- 8: Différents paramètres de modèles de complexité 2×2

ResNeXt-50 et ResNeXt-101 ont de faibles erreurs lorsque la cardinalité est élevée, de plus, ces réseaux comportent bien dans les problèmes qui utilisent les images C'est l'une des autres raisons pour lesquelles nous nous sommes appuyés sur le choix de ResNeXt50 dans cette expérience scientifique, dont nous discuterons ses détails dans la partie suivante.

Par ailleurs, dans les problèmes utilisant les réseaux de neurones, il est standard d'utiliser Softmax pour la classification. Softmax est implémenté via une couche de réseau de neurones juste avant la couche de sortie. En particulier, la couche Softmax doit avoir le même nombre de nœuds que la couche de sortie. Pour bien comprendre le fonctionnement de cette fonction. Soit \mathbf{h} l'activation des nœuds de l'avant-dernière couche, \mathbf{W} est le poids reliant l'avant-dernière couche à la couche Softmax, l'entrée totale dans une couche Softmax, donnée par l'équation (5-4), est :

$$a_i = \sum_k h_k W_{ki} \quad (\text{Éq. 5-4})$$

La Softmax donne comme sortie une distribution de probabilité discrète donnée par l'équation (5-5).

$$p_i = \frac{\exp(a_i)}{\sum_j^k \exp(a_j)} \quad (\text{Éq. 5-5})$$

Cette distribution de probabilité est utilisée pour prédire les résultats utilisant argmax, où l'argmax est la fonction qui renvoie le rang pour lequel le maximum est atteint. La classe prédite \hat{y} serait (Éq. 5-6):

$$\begin{aligned} &= \arg_i \max p_i \\ &= \arg_i \max a_i \end{aligned} \quad (\text{Éq. 5-6})$$

D'une manière générale, Softmax interprète plutôt les résultats comme des probabilités pour chaque classe.

3.4 Machine à vecteurs de support (SVM)

La machine à vecteurs de support (SVM) a été développée par Vapnik [258] pour la classification binaire. Son objectif est de trouver l'hyperplan optimal $f(w, x) = w \cdot x + b$ pour séparer deux classes dans un jeu de données donné, avec des caractéristiques $x \in R^m$.

SVM apprend les paramètres w en résolvant un problème d'optimisation (Éq. 5-7).

$$\min \frac{1}{P} w^t w + c \sum_{i=1}^P \max(0, 1 - y_i' (w^T x_i + b)) \quad (\text{Éq. 5-7})$$

Où w^T et w est la norme de Manhattan (également appelée norme $L1$), C est le paramètre de pénalité (peut être une valeur arbitraire ou une valeur sélectionnée valeur à l'aide de l'optimisation des hyperparamètres), y' est l'étiquette réelle et $w^T x + b$ est la fonction prédictive. L'équation 5-7 est connue sous le nom de $L1 - SVM$, avec la perte de charnière standard. Son homologue différentiable, $L2 - SVM$ (Éq. 5-8) fournit des résultats plus stables [258].

$$\min \frac{1}{p} \|w\|_2^2 + c \sum_{i=1}^p \max \left(0, 1 - y_i (w^T x_i + b) \right)^2 \quad (\text{Éq. 5-8})$$

Où $\|w\|_2$ est la norme euclidienne (également appelée norme L_2), avec la perte de charnière au carré.

Compte tenu des données d'entraînement et de leurs étiquettes correspondantes (x_n, t_n) , $n = 1, \dots, N$, $x_n \in \mathbb{R}^D$, $t_n \in \{-1, 1\}$, pour prédire l'étiquette de classe d'une donnée de test x SVM utilise la formule (Éq. 5-9), cette formule donne si un nouvel exemple x appartient à la classe -1 ou à la classe $+1$.

$$\text{arg}_t \max (W^T x) t \quad (\text{Éq. 5-9})$$

Comme la formule de prédiction montre, la prédiction de la classe n'est pas encore la même que Softmax, car SVM de base peut prédire seulement des problèmes binaires. Toutefois, il existe des approches pour que SVM soit multiclasse, pour prédire plusieurs objets. La façon la plus simple est d'utiliser l'approche dite one-vs-rest. Pour les problèmes de k classes. Cette approche utilise un changement de variable de la fonction \mathbf{W} par \mathbf{a} , alors la sortie du SVM est désignée comme suit (Éq. 5-10) :

$$a_k(x) = W^T x \quad (\text{Éq. 5-10})$$

La fonction a_k présente les différentes fonctions de classification des SVM associés aux classes (c'est à dire utilise k fonction de décision) au lieu d'une seule fonction, cette fonction détermine la classe de chaque entrée x . Après cette opération, la classe prédite serait (Éq. 11):

$$\text{arg}_k \max a_k(x) \quad (\text{Éq. 5-11})$$

À noter ici que la prédiction à l'aide de SVM multiclasse est exactement la même que l'utilisation d'un Softmax (Éq. 5-6), d'où la possibilité d'utilisation de SVM avec des réseaux de neurones pour la fonction de classification.

3.5 Détection des mauvaises herbes basé sur le modèle hybride proposé

Dans les applications agricoles, les résultats précis des prédictions sont cruciaux, car toute erreur de prédiction peut entraîner des pertes énormes et un gaspillage d'herbicide. Ainsi, pour améliorer encore la précision de la prédiction, nous avons implémenté l'apprentissage incrémentiel de la reconnaissance de formes. Le modèle de base appliqué ici, comme le montre la figure 5-9, est à base de ResNeXt-50 est utilisé pour l'extraction de caractéristiques des images appartenant aux 4 classes. Les caractéristiques extraites sont ensuite classées par le classificateur linéaire SVM qui prédit si une image est une mauvaise herbe nuisible ou ne pas. Ceci s'ajoute bien sûr aux autres étapes nécessaires à tout apprentissage d'algorithmes, dont nous avons longuement parlé dans les parties précédentes (prétraitements, data-augmentation...). Ce réseau proposé, selon les dernières publications scientifiques, n'a pas encore été abordé.

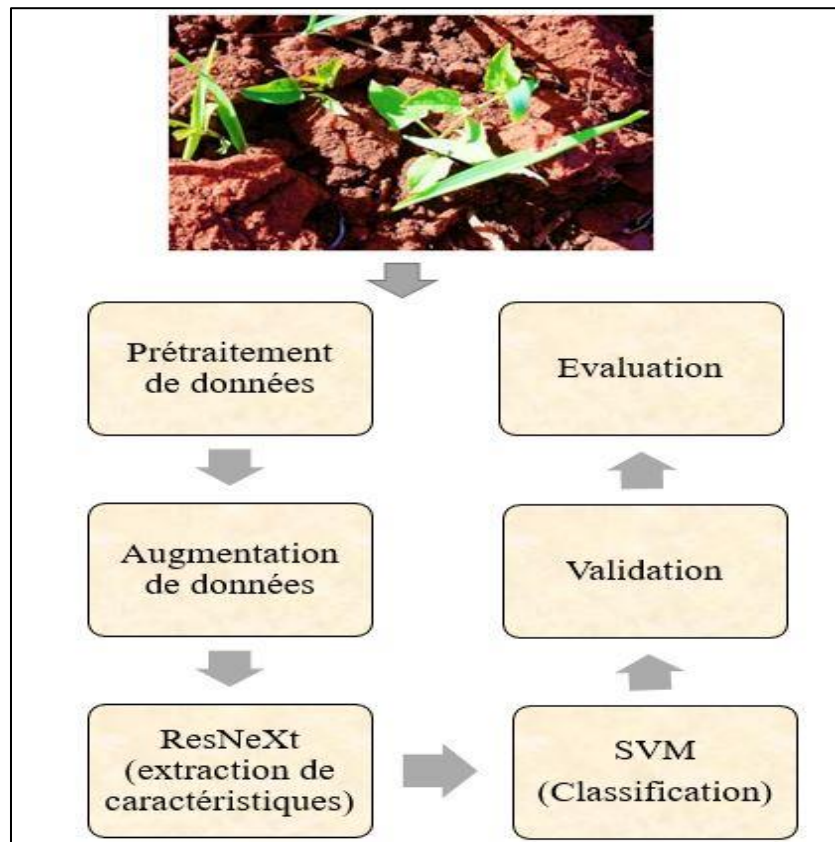


Figure 5- 9: Le modèle hybride proposé

Concernant les paramètres utilisés, on peut citer une taille de lot de 4 (Batch Size), la fonction d'activation est ReLU et Softmax, l'optimiseur est Adam. Le modèle est entraîné sur notre jeu de données et la partie suivante discute des résultats obtenus.

3.6 Résultats et discussion

Comme la taille de l'ensemble de données est moyenne, nous avons effectué une augmentation des données pour obtenir des résultats fiables. L'accuracy a été améliorée par l'architecture hybride ResNeXt-SVM qui a donné des résultats exceptionnellement fiables d'une précision de 98% pour la détection de mauvaises herbes, comme la montrent les figures 10 et 11.




Figure 5- 10: Les performances du modèle après l'apprentissage




Figure 5- 11: Le taux d'erreur du modèle après l'apprentissage

D'après les résultats ci-dessous, nous pouvons voir que les métriques de performance enregistrées dans Tensorboard ont montré une précision intéressante atteignant 98% (figure 5-10). Une erreur

totale a diminué à 29 % (figure 5-11). L'apprentissage de ResNeXt-SVM est plus rapide que les autres modèles, environ 4 heures d'apprentissage. Cela signifie que les performances du modèle peuvent toujours s'améliorer à chaque époque. Les prédictions sur les images de test donnaient le même fait, la plupart des prédictions sont correctes avec un taux de 98%.

Le modèle a donné une bonne précision d'entraînement (accuracy) de 98% et une précision de validation de 97%, ce qui est nettement supérieur à celui des autres modèles d'architecture ResNeXt, ResNet [116, 117, 118, 259], nous les avons comparés avec la méthode proposée en termes de précision. La perte d'entraînement a diminué progressivement de la valeur initiale de 0,9 à sa valeur optimale et la plus basse de 0,28. Avec l'application de l'apprentissage incrémentiel où l'architecture ResNeXt est utilisée pour l'extraction de caractéristiques en profondeur et le classificateur linéaire SVM est utilisé pour la classification, les résultats sont très précis par rapport à toutes les méthodes utilisées dans notre étude. Il a donné une meilleure précision de validation et une meilleure précision d'entraînement. Ainsi, notre modèle proposé ResNeXt-SVM donne des prédictions très précises et fiables de la détection des mauvaises herbes sur les images de test.

Nous avons comparé notre approche avec les modèles de base dont nous avons discuté dans les travaux connexes. Le tableau 5-1 montre l'accuracy de chaque modèle, ainsi le résultat de notre modèle, le modèle hybride donné une précision importante par rapport aux résultats des modèles de comparaison ResNet et ResNeXt.

Tableau 5- 1. Comparaison des résultats obtenus avec ceux de ResNet et ResNeXt.

Description du problème de recherche	Données	Modèle	Résultat
Détection et classification des adventices dans la culture	Des images de cultures captées avec un drone	ResNet	95,1%
		ResNeXt	97,4%
		ResNeXt-SVM	98%

La méthode de classification des mauvaises herbes proposée a trois contributions majeures par rapport aux méthodes existantes comme suit.

Première contribution : À notre connaissance, il s'agit de la première application du modèle combiné de ResNeXt et SVM dans la classification des mauvaises herbes. Ce modèle de combinaison peut utiliser efficacement les caractéristiques temporelles et spatiales de l'information pour obtenir de meilleurs résultats de classification.

Deuxième contribution : En utilisant la méthode pré-entraînée du modèle ResNeXt, ses poids choisis sont proches d'un bon optimum local, de sorte qu'ils sont maintenus dans une plage de gradient élevé et qu'ils peuvent être efficacement affinés.

Troisième contribution : le modèle de ResNeXt-SVM est plus efficace pour la détection des mauvaises herbes, simple à implémenter, avec une précision d'environ 98%. Nous pouvons donc l'utiliser dans un système de détection de mauvaises herbes robotisé basé sur Raspberry Pi4. Cela contribuera à détecter les adventices en temps réel pour réaliser une pulvérisation localisée des adventices au lieu de les propager à grande échelle, ce qui sera bénéfique au niveau de la quantité de l'herbicide exploitée et protège l'environnement et fait gagner du temps, ce sera une prise de décision automatisée sans aucune intervention humaine.

4. Conclusion

L'agriculture intelligente et de précision englobe plusieurs domaines d'application, dont les plus populaires sont la détection des maladies des plantes et des feuilles, la classification de la couverture végétale, la reconnaissance des plantes et l'identification des mauvaises herbes. L'adoption et le développement de l'agriculture de précision nécessitent de nouveaux modèles de deep learning. Dans ce chapitre, nous avons proposé un classificateur hybride à base d'une combinaison équilibrée de deep learning et d'apprentissage automatique qui a été mis en œuvre pour l'extraction de caractéristiques et la détection des mauvaises herbes dans les champs agricoles. Notre modèle suggéré est très précis par rapport à d'autres architectures de deep learning standard en termes de précision et de plusieurs autres métriques d'évaluation. Le modèle hybride ResNeXt-SVM pourrait fournir des résultats précis, le résultat obtenu par la méthode proposée est de 98%, ce qui est supérieur au ResNet et au ResNeXt dont les résultats de précision sont respectivement de 95,1% et 97,4%. Ainsi, le modèle proposé peut-il être appliqué sur n'importe quel type et sur n'importe quelle taille de datasets liés à des domaines qui nécessitent des décisions très précises. Cependant, la précision du modèle peut être encore améliorée en appliquant des méthodes d'équilibrage de classe de l'apprentissage automatique. Ainsi, ce modèle est susceptible de donner des résultats prometteurs pour la détection des mauvaises herbes basée sur l'application des technologies de pointe de l'intelligence artificielle.

Conclusion générale et perspectives

Le 16 décembre 2021, une volonté commune de renforcer la coordination pour une transformation digitale au service du développement du secteur agricole a été concrétisée par la tenue d'une réunion de travail à laquelle ont assisté le ministre de l'Agriculture, de la Pêche Maritime, du Développement Rural et des Eaux et Forêts et la Ministre de la Transition Numérique et de la Réforme de l'Administration. Cette rencontre a porté sur le dédoublement des efforts et la coordination entre les deux ministères en vue de l'élaboration d'un programme de travail commun pour renforcer les synergies nécessaires à l'essor de la transformation digitale du secteur agricole. Les deux acteurs ont échangé autour de la transformation digitale dans le domaine agricole et agro-alimentaire, ainsi que les leviers prioritaires pour initier le virage vers une Agriculture 4.0 dans le cadre de la stratégie « Génération Green 2020-2030 », présentée par le département de l'agriculture. C'était également une occasion pour rappeler les chantiers transverses en accompagnement des différents programmes engagés pour la digitalisation des différents macro-processus de l'agriculture au profit de la modernisation du secteur agricole et agro-industriel.

En alignement avec cette vision, ce travail de recherche offre une contribution académique considérée comme étant un maillon, parmi d'autres, dans une chaîne digitale de valeurs agricoles susceptible d'être développée davantage à travers d'autres thèses futures. Notre contribution met en exergue cette doctrine de transition numérique ou digitalisation du secteur agricole tirant profit de l'explosion numérique, boostée, d'ailleurs, par la pandémie du Covid-19 dans pratiquement tous les domaines. Il s'agit de repenser l'agriculture sous ses différentes composantes à l'ère du digital, en s'appuyant sur les nouvelles technologies de l'information et de la communication qui continuent de s'imposer, plus que jamais, dans le secteur agricole et agro-alimentaire, en vue d'une agriculture moderne, Smart et digitale. Dans cette optique, le recours à des technologies de pointe telles que l'Intelligence Artificielle, le « Big Data Analytics », le « Cloud Computing » ou encore l'internet des objets « IoT » va de pair avec l'amélioration de la performance en termes de production et de commercialisation dans plusieurs filières de l'agriculture à savoir : l'élevage et produits laitiers (bovins, ovins, caprins), l'arboriculture, l'horticulture, l'aquaculture, l'apiculture, les plantes aromatiques, le maraichage, le machinisme agricole, l'agriculture biologique, etc.

Ne pouvant guère couvrir exhaustivement ces domaines, nous nous sommes focalisés, dans ce travail de recherche, sur la culture des champs touchant un facteur essentiel ayant un impact direct sur la production agricole dans les parcelles. Il s'agit de la détection des mauvaises herbes qui concurrencent tout type de plantes et représentent un ennemi fatal pour l'agriculteur, en dépit des conditions météorologiques favorables. En effet, le recours aux différentes techniques de « machine learning » et plus précisément « deep learning » intégré dans une vision d'intelligence artificielle appliquée au domaine de la gestion des champs agricoles est susceptible de renforcer l'identification, la détection et la prédiction des herbes nuisibles, ainsi qu'à l'aide à la prise de décision quant au choix des herbicides spécifiques pouvant y faire face et réduire considérablement les pertes visant l'amélioration de la performance en termes de production, de rendement et de commercialisation.

Pour cette fin, nous avons proposé des modèles d'apprentissage en profondeur qui peuvent être exploités de par leurs capacités d'entraînement et de détection dans plusieurs problèmes de l'agriculture. Ainsi nous avons introduit de nombreuses façons de créer, d'optimiser et d'entraîner d'autres modèles sur les données. Nous avons considéré, également, des solutions pratiques pour régulariser et améliorer les résultats. Ces contributions ont été apportées à travers un ensemble d'études ayant, chacune, un objectif précis intégré dans une vision globale de transformation digitale de l'agriculture. À l'issue de ces études, il a été constaté que les performances d'un modèle d'apprentissage en profondeur dépendent de nombreux facteurs tels que les caractéristiques techniques de la machine, le nombre de paramètres dans le réseau, le volume de données, le nombre de couches, etc. Or, selon une revue de littérature effectuée dans ce domaine, l'apprentissage en profondeur « deep learning » est utilisé essentiellement pour l'extraction des caractéristiques ainsi que la classification qui est réalisée, pratiquement, par la fonction d'activation Softmax dans divers algorithmes multi-classes tels que le CNN. En outre, nous avons relevé qu'un groupe de chercheurs ont changé cette fonction de classification visant l'obtention de meilleurs résultats, ce qui nous a représenté une source d'inspiration pour changer Softmax et le substituer par machine à vecteurs de support SVM (Support Vector Machine) en vue d'une meilleure performance. Par ailleurs, fouillant dans les algorithmes des réseaux de neurones, il nous a été donné de constater que le modèle ResNeXt était très peu utilisé dans notre volet de recherche et aurait plus d'avantages dans la détection des mauvaises herbes en comparaison avec les algorithmes classiques limités en termes de prédiction et de performance. Cela étant, la solution

proposée était de construire un modèle hybride à base d'une combinaison équilibrée de deep learning et d'apprentissage automatique (ResNeXt-SVM) qui a été mis en œuvre pour l'extraction de caractéristiques et la détection des mauvaises herbes dans les champs agricoles. Selon notre humble constatation, cette fusion n'a jamais été abordée par la communauté scientifique, ce qui reflète la touche originale attribuée à ce travail de recherche. Le nouvel algorithme proposé a été testé sur les problèmes de deep learning, que nous avons rencontrés dans nos expériences pratiques. Il a révélé sa grande performance et capacité à distinguer les mauvaises herbes au milieu d'une arborescence abondante de plantes.

En général, nous estimons que ce travail de recherche a apporté les contributions suivantes :

- Un Benchmark des approches et techniques de digitalisation de l'agriculture ;
- Une étude de cas pratique utilisant les données locales de la région de Béni Mellal-Khénifra, ayant mis en relief la valeur ajoutée de l'IA, à travers l'entraînement de quelques modèles de DL, pour une Smart détection des mauvaises herbes intégrée dans une vision de transformation digitale de l'agriculture ;
- Renforcement et amélioration de quelques algorithmes de deep learning au profit de la détection des mauvaises herbes dans les champs agricoles ;
- Proposition d'un modèle hybride ResNeXt-SVM basé sur une combinaison de modèles de deep learning pour la détection des mauvaises herbes.

Ce travail de recherche s'est vu contrarié par des difficultés et limites liées essentiellement aux tailles et types des données traitées. En outre, nous avons heurté des difficultés pour obtenir des données réelles officielles locales utiles aux entraînements des modèles, car les mauvaises herbes diffèrent d'une région à l'autre, selon le climat, la terre et d'autres facteurs. Nous ajoutons également les difficultés de la préparation des données qui prend énormément de temps, ainsi la préparation et l'apprentissage des modèles nécessite un environnement matériel puissant sans oublier que la bonne configuration du modèle appliqué demande une longue durée et beaucoup d'efforts. En effet le processus de développement d'algorithmes de deep learning peut prendre des mois en vain.

En perspective, bien que les objectifs visés initialement, soient atteints, ce travail est loin d'être complet et nécessite de la continuité et de la prolifération des efforts pour ressortir des modèles hybrides typiques basés, éventuellement, sur d'autres algorithmes en vue d'une projection

adaptative sur différentes filières de l'agriculture telles que l'identification des ravageurs, des maladies, la classification des cultures, l'identification des stages de croissance des cultures, l'évaluation de l'occupation du sol, le comptage des animaux, etc. Nous sommes également impatients de publier les datasets que nous avons préparées dans ces expériences, qui contiennent des images de mauvaises herbes de notre région, pouvant être utilisées par la communauté scientifique. Mieux encore, l'implémentation de ces modèles dans un système embarqué à base de Raspberry pourrait assurer la détection et l'identification des mauvaises herbes en temps réel, en vue d'une bonne gestion de la culture et optimisation des charges pour une meilleure production dans les parcelles agricoles.

Production scientifique

1. Récapitulatif en chiffres

Type	Nombre
Articles publiés dans des journaux indexés Scopus et/ou WoS	9
Articles de conférences dont le proceeding est indexé Scopus	2
Communications internationales avec comité de programme	7
Chapitre de livre et communication nationale	2

2. Articles publiés par des journaux indexés Scopus et/ou WoS

- ❶ **B. Jabir, N. Falih**, (2022). *A new hybrid model of Deep Learning ResNeXt-SVM for Weed Detection*. International Journal of Intelligent Information Technologies (IJIT), 18(2).
- ❷ **B. Jabir, & N. Falih**, (2022). *Deep learning-based decision support system for weeds detection in wheat fields*. International Journal of Electrical & Computer Engineering (2088-8708), 12(1).
- ❸ **B. Jabir, N. Falih, L. Rabhi**, (2021). *RNN- and CNN-based weed detection for crop improvement: An overview*. Foods and Raw Materials, 2021, vol. 9, no. 2, pp. 387-396.
- ❹ **B. Jabir, N. Falih**, (2021). *Dropout, a basic and effective regularization method for a Deep Learning model: A case study*. Indonesian Journal of Electrical Engineering and Computer Science, 24(2), pp. 1009–1016.
- ❺ **B. Jabir, N. Falih, A. Sarih, & A. Tannouche**, (2021). *A Strategic Analytics Using Convolutional Neural Networks for Weed Identification in Sugar Beet Fields*. Agris on-line Papers in Economics and Informatics, 1(March), 49-57.
- ❻ **B. Jabir, N. Falih, K. Rahmani**, (2021). *Accuracy and Efficiency Comparison of Object Detection Open-Source Models*. International Journal of Online & Biomedical Engineering, 17(5).
- ❼ **B. Jabir, N. Falih**, (2021). *Big Data Analytics Opportunities and Challenges for the Smart Enterprise*. International Journal on Technical and Physical Problems of Engineering (IJTPE), 13(2), 20-26.
- ❽ **B. Jabir, N. Falih, K. Rahmani**, (2019). *HR analytics a roadmap for decision making: case study*. Indonesian Journal of Electrical Engineering and Computer Science, 15(2).
- ❾ **N. Falih, B. Jabir, K. Rahmani**, (2018). *Systemic approach to optimizing Information Technology resource as a contribution to Information System governance*. Indonesian Journal of Electrical Engineering and Computer Science, 12(4).

3. Articles de conférences dont le proceeding est indexé Scopus

- ❶ **N. Falih, B. Jabir, L. RABHI**, (2021, May). *Structural Analysis using Galois Lattice Concept for Strategic Business Processes Alignment*. In 2021 7th International Conference on Optimization and Applications (ICOA) (pp. 1-5). IEEE.
- ❷ **B. Jabir, N. Falih**, (2020). *Digital agriculture in Morocco, opportunities and challenges*". IEEE 6th International Conference on Optimization and Applications (ICOA), Beni Mellal, Morocco, pp. 1-5.

4. Communications internationales avec comité de programme

- ❶ **N. Falih, B. Jabir, L. RABHI**, (2021, May). *Structural Analysis using Galois Lattice Concept for Strategic Business Processes Alignment*. In 2021 7th International Conference on Optimization and Applications (ICOA) (pp. 1-5). IEEE.
- ❷ **B. Jabir, N. Falih, K. Rahmani**, (March 2021). *Big data Analytics Opportunities and Challenges for the Smart Enterprise*" International Network of Research and Training, Agadir, Morocco.
- ❸ **B. Jabir, N. Falih, K. Rahmani**, (2018). *Big data analytics opportunities and challenges for the smart enterprise*. The 1st International Conference of Computer Science and Renewable Energies « ICCSRE'2018 » Ouarzazat-Morocco.
- ❹ **B. Jabir, N. Falih, K. Rahmani**, (2018). *Strategic analytic for smart and agile entreprise*. 12th edition of the international Conference on Advances Systems. Marrakech - Morocco.
- ❺ **B. Jabir, N. Falih, K. Rahmani**, (April 2018). *From Big data to Smart Data_A real-time Data Analytics Approach for Decision Making*. The 4th International Conference on Business Intelligence, Beni Mellal, Morocco.
- ❻ **B. Jabir, N. Falih, K. Rahmani**, (May 2018). *Strategies Analytics A Roadmap to Make A Decision for Smart Enterprise*. Rencontre sur la Recherche et l'Innovation, Béni Mellal (Maroc).
- ❼ **B. Jabir, N. Falih, K. Rahmani**, (2018) *The Business Analytics in Telecom area*. First International Conference on Signals, Automation and Telecommunications, Beni Mellal, Morocco.

5. Chapitre de livre et communication nationale

- ❶ Chapitre de livre en cours de publication Elsevier: **B. Jabir, N. Falih**. (2022). *Big data analytics opportunities and challenges to inform strategic and operational decisions for smart enterprise*. Hassanien - Artificial Intelligence and Industry 4.0, Elsevier Science, ISBN: 9780323906395.
- ❷ **B. Jabir, N. Falih, K. Rahmani**. (2018). *Strategic analytics as a roadmap for decision-making support in the smart enterprise*. revue de l'entrepreneuriat et de l'innovation, Vol. 2, No 6.

Références

- [1] Ozdogan, B., Gacar, A., & Aktas, H. (2017). Digital agriculture practices in the context of agriculture 4.0. *Journal of Economics Finance and Accounting*, 4(2), 186-193.
- [2] Trendov, M., Varas, S., & Zeng, M. (2019). Digital technologies in agriculture and rural areas: status report. *Digital technologies in agriculture and rural areas: status report*.
- [3] Tang, S., Zhu, Q., Zhou, X., Liu, S., & Wu, M. (2002, June). A conception of digital agriculture. In *IEEE international geoscience and remote sensing symposium (Vol. 5, pp. 3026-3028)*. IEEE.
- [4] Andrade-Sanchez, P., & Heun, J. T. (2010), Understanding Technical Terms and Acronyms Used in Precision Agriculture, The University of Arizona, Arizona Cooperative Extension Bulletin AZ1534.
- [5] Mzini, L. B. (2020). Contribution of digitalisation for agriculture (D4Ag) in food security information system to enhance public participation. *International Conference on Public Administration and Development Alternative (IPADA)*.
- [6] Yane, D. (2010, October), Research and Analysis about System of Digital Agriculture Based on a Network Platform, In *International Conference on Computer and Computing Technologies in Agriculture (pp. 274-282)*. Springer Berlin Heidelberg.
- [7] Hrustek, L. (2020). Sustainability driven by agriculture through digital transformation. *Sustainability*, 12(20), 8596.
- [8] Jabir, B., Falih, N., Big data analytics opportunities and challenges for the smart enterprise. *International Journal on Technical and Physical Problems of Engineering (IJTPE)*, (47), 20-26.
- [9] Jabir, B., Falih, N., & Rahmani, K. (2019). HR analytics a roadmap for decision making: case study. *Indonesian Journal of Electrical Engineering and Computer Science (IJEECS)*, 15(2), 979-990.
- [10] Jabir, B., & Falih, N. (2020, April). Digital agriculture in Morocco, opportunities and challenges. In *2020 IEEE 6th International Conference on Optimization and Applications (ICOA) (pp. 1-5)*. IEEE.
- [11] United Nations (2009), *World Population Prospects 2019*, Disponible sur: <https://esa.un.org/unpd/wpp> [Consulté le 24 septembre 2021].
- [12] World Health Organization (2021), *Global and regional food consumption*, Disponible sur: http://www.who.int/nutrition/topics/3_foodconsumption/en/index4.html [Consulté le 22 septembre 2021].
- [13] De Clercq, M., Vats, A., & Biel, A. (2018). Agriculture 4.0: The future of farming technology. *Proceedings of the World Government Summit, Dubai, UAE*, 11-13.
- [14] Sharma, N., & Singhvi, R. (2017). Effects of chemical fertilizers and pesticides on human health and environment: a review. *International journal of agriculture, environment and biotechnology*, 10(6), 675-680.
- [15] IPCC, (2014), *Climate Change 2014: Synthesis Report. Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*, Disponible sur: www.ipcc.ch/report/ar5/syr/ [Consulté le 26 septembre 2021].
- [16] FAO (2016), *Changement climatique, agriculture et sécurité alimentaire*, Disponible sur: <http://www.fao.org/publications/sofa/2016/fr/> [Consulté le 28 septembre 2021].

- [17] Buyya, R., Yeo, C. S., Venugopal, S., Broberg, J., & Brandic, I. (2009). Cloud computing and emerging IT platforms: Vision, hype, and reality for delivering computing as the 5th utility. *Future Generation computer systems*, 25(6), 599-616.
- [18] Zhou, H., Hu, Y., Su, J., de Laat, C., & Zhao, Z. (2018, June). Cloudstorm: An application-driven framework to enhance the programmability and controllability of cloud virtual infrastructures. In *International Conference on Cloud Computing* (pp. 265-280). Springer, Cham.
- [19] Symeonaki, E. G., Arvanitis, K. G., & Piromalis, D. D. (2017, September). Cloud computing for IoT applications in climate-smart agriculture: A review on the trends and challenges toward sustainability. In *International Conference on Information and Communication Technologies in Agriculture, Food & Environment* (pp. 147-167). Springer, Cham.
- [20] Choudhary, S. K., Jadoun, R. S. and Mandoriya, H. L. (2016) "Role of Cloud Computing Technology in Agriculture Fields", *Computer Engineering and Intelligent Systems*, Vol. 7, No. 3, pp. 1-7. ISSN 2222-1719.
- [21] Botta, A., De Donato, W., Persico, V., & Pescapé, A. (2016). Integration of cloud computing and internet of things: a survey. *Future generation computer systems*, 56, 684-700.
- [22] Ji, C., Shao, Q., Sun, J., Liu, S., Pan, L., Wu, L., & Yang, C. (2016). Device data ingestion for industrial Big data platforms with a case study. *Sensors*, 16(3), 279.
- [23] Ip, R. H., Ang, L. M., Seng, K. P., Broster, J. C., & Pratley, J. E. (2018). Big data and machine Learning for crop protection. *Computers and Electronics in Agriculture*, 151, 376-383.
- [24] Lakhwani K, Gianey H, Agarwal N, and Gupta S, (2019). Development of IoT for smart agriculture a review *Emerging Trends in Expert Applications and Security* pp 425-32
- [25] Reichardt, M., & Jürgens, C. (2009). Adoption and future perspective of precision farming in Germany: Results of several surveys among different agricultural target groups. *Precision Agriculture*, 10, 73–94.
- [26] Talavera, J. M., Tobón, L. E., Gómez, J. A., Culman, M. A., Aranda, J. M., Parra, D. T., ... & Garreta, L. E. (2017). Review of IoT applications in agro-industrial and environmental fields. *Computers and Electronics in Agriculture*, 142, 283-297.
- [27] Coble, K. H., Mishra, A. K., Ferrell, S., & Griffin, T. (2018). Big data in agriculture: A challenge for the future. *Applied Economic Perspectives and Policy*, 40(1), 79-96.
- [28] Delgado, J. A., Short Jr, N. M., Roberts, D. P., & Vandenberg, B. (2019). Big data analysis for sustainable agriculture on a geospatial cloud framework. *Frontiers in Sustainable Food Systems*, 3, 54.
- [29] Patrício, D. I., & Rieder, R. (2018). Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. *Computers and electronics in agriculture*, 153, 69-81.
- [30] Castenedo, F. (2013). A review of data fusion technique. *The Scientific World Journal*.
- [31] Dahikar, S. S., & Rode, S. V. (2014). Agricultural crop yield prediction using artificial neural network approach. *International journal of innovative research in electrical, electronics, instrumentation and control engineering*, 2(1), 683-686.
- [32] Rani, P. M. N., Rajesh, T., & Saravanan, R. (2011). Expert systems in agriculture: A review. *Journal of Computer Science and Applications*, 3(1), 59-71.
- [33] Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine Learning in agriculture: A review. *Sensors*, 18(8), 2674.

- [34] Joy, J., & Sreekumar, K. (2014). A survey on expert system in agriculture. *International journal of computer science and information technologies*, 5, 7861-7864.
- [35] Mishra, S., & Akankasha Deep, V. (2014). Expert Systems in Agriculture. An Overview. *International Journal of Science Technology and Engineering*, 1(5):45-49.
- [36] Mishra, S., Mishra, D., & Santra, G. H. (2016). Applications of machine Learning techniques in agricultural crop production: a review paper. *Indian Journal of Science and Technology*, 9(38), 1-14.
- [37] Elsayed, K. M. F., Ismail, T., & Ouf, N. S. (2018). A review on the relevant applications of machine Learning in agriculture. *Ijireeice*, 6(8), 1-17.
- [38] Reshma, S. J., & Pillai, A. S. (2016, December). Impact of Machine Learning and Internet of Things in agriculture: state of the art. In *International Conference on Soft Computing and Pattern Recognition* (pp. 602-613). Springer, Cham.
- [39] Bronson, K., & Knezevic, I. (2016). Big data in food and agriculture. *Big data & Society*, 3(1), 2053951716648174.
- [40] Ribarics, P. (2016). Big data and its impact on agriculture. *Ecocycles*, 2(1), 33-34.
- [41] Wolfert, S., Ge, L., Verdouw, C., & Bogaardt, M. J. (2017). Big data in smart farming—a review. *Agricultural systems*, 153, 69-80.
- [42] Kamilaris, A., Kartakoullis, A., & Prenafeta-Boldú, F. X. (2017). A review on the practice of Big data analysis in agriculture. *Computers and Electronics in Agriculture*, 143, 23-37.
- [43] Himesh, S., Prakasa Rao, E. V. S., Gouda, K. C., Ramesh, K. V., Rakesh, V., & Mohapatra, G. N. (2018). Digital revolution and Big Data: A new revolution in agriculture. *CAB Rev*, 13(21), 1-7.
- [44] Saggi, M. K., & Jain, S. (2018). A survey towards an integration of Big data analytics to big insights for value-creation. *Information Processing & Management*, 54(5), 758-790.
- [45] Nguyen, T., Li, Z. H. O. U., Spiegler, V., Ieromonachou, P., & Lin, Y. (2018). Big data analytics in supply chain management: A state-of-the-art literature review. *Computers & Operations Research*, 98, 254-264.
- [46] Rabah, K. (2018). Convergence of AI, IoT, Big data and blockchain: a review. *The lake institute Journal*, 1(1), 1-18.
- [47] Kamble, S. S., Gunasekaran, A., & Gawankar, S. A. (2020). Achieving sustainable performance in a data-driven agriculture supply chain: A review for research and applications. *International Journal of Production Economics*, 219, 179-194.
- [48] Riggins, F. J., & Wamba, S. F. (2015, January). Research directions on the adoption, usage, and impact of the internet of things through the use of Big data analytics. In *2015 48th Hawaii International Conference on System Sciences* (pp. 1531-1540). IEEE.
- [49] Nukala, R., Panduru, K., Shields, A., Riordan, D., Doody, P., & Walsh, J. (2016, June). Internet of Things: A review from 'Farm to Fork'. In *2016 27th Irish Signals and Systems Conference (ISSC)* (pp. 1-6). IEEE.
- [50] Brewster, C., Roussaki, I., Kalatzis, N., Doolin, K., & Ellis, K. (2017). IoT in agriculture: Designing a Europe-wide large-scale pilot. *communications magazine*, 55(9), 26-33.
- [51] Khan, S. F., & Ismail, M. Y. (2018). An Investigation into the Challenges and Opportunities Associated with the Application of Internet of Things (IoT) in the Agricultural Sector-A Review. *J. Comput. Sci.*, 14(2), 132-143.
- [52] Luque, A., Peralta, M. E., De Las Heras, A., & Córdoba, A. (2017). State of the Industry 4.0 in the Andalusian food sector. *Procedia Manufacturing*, 13, 1199-1205.

- [53] Gómez-Chabla R., Real-Avilés K., Morán C (2019) IoT Applications in Agriculture: A Systematic Literature Review. In: Valencia-García R., CioppoMorstadt J., Vera-Lucio N., Bucaram-Leverone M. (eds) ICT for Agriculture and Environment. CITAMA2019 2019. Advances in Intelligent Systems and Computing, vol 901. Springer, Cham
- [54] Shi, X., An, X., Zhao, Q., Liu, H., Xia, L., Sun, X., & Guo, Y. (2019). State-of-the-art internet of things in protected agriculture. *Sensors*, 19(8), 1833.
- [55] Rabah, K. (2017). Overview of blockchain as the engine of the 4th industrial revolution. *Mara Research Journal of Business & Management*, 1(1), 125-135.
- [56] Bermeo-Almeida, O., Cardenas-Rodriguez, M., Samaniego-Cobo, T., Ferruzola-Gómez, E., Cabezas-Cabezas, R., & Bazán-Vera, W. (2018, November). Blockchain in agriculture: A systematic literature review. In *International Conference on Technologies and Innovation* (pp. 44-56). Springer, Cham.
- [57] Ko, T., Lee, J., & Ryu, D. (2018). Blockchain technology and manufacturing industry: Real-time transparency and cost savings. *Sustainability*, 10(11), 4274.
- [58] Tripoli, M., & Schmidhuber, J. (2018). *Emerging Opportunities for the Application of Blockchain in the Agri-food Industry*. FAO and ICTSD: Rome and Geneva. Licence: CC BY-NC-SA, 3.
- [59] Queiroz, M. M., Telles, R., & Bonilla, S. H. (2019). Blockchain and supply chain management integration: a systematic review of the literature. *Supply Chain Management: An International Journal*.
- [60] Zhao, G., Liu, S., Lopez, C., Lu, H., Elgueta, S., Chen, H., & Boshkoska, B. M. (2019). Blockchain technology in agri-food value chain management: A synthesis of applications, challenges and future research directions. *Computers in Industry*, 109, 83-99.
- [61] Xiong, H., Dalhaus, T., Wang, P., & Huang, J. (2020). Blockchain technology for agriculture: applications and rationale. *frontiers in Blockchain*, 3, 7.
- [62] Srinivasan, A. (2006). Precision agriculture: An overview. *Handbook of Precision Agriculture*, 33-48.
- [63] Aubert, B. A., Schroeder, A., & Grimaudo, J. (2012). IT as enabler of sustainable farming: An empirical analysis of farmers' adoption decision of precision agriculture technology. *Decision Support Systems*, 54, 510–520.
- [64] Barbedo, J. G. (2018). Factors influencing the use of Deep Learning for plant disease recognition. *Biosystems engineering*, 172, 84-91.
- [65] Ferentinos, K. P. (2018). Deep Learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311-318.
- [66] Zhang, X., Qiao, Y., Meng, F., Fan, C., & Zhang, M. (2018). Identification of maize leaf diseases using improved Deep convolutional neural networks. *IEEE Access*, 6, 30370-30377.
- [67] Mulla, D. J. (2013). Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps 5. *biosystems engineering*, 114(358), e371.
- [68] Seelan, S. K., Laguette, S., Casady, G. M., & Seielstad, G. A. (2003). Remote sensing applications for precision agriculture: A Learning community approach. *Remote sensing of environment*, 88(1-2), 157-169.
- [69] Gao, F., Anderson, M. C., Zhang, X., Yang, Z., Alfieri, J. G., Kustas, W. P., ... & Prueger, J. H. (2017). Toward mapping crop progress at field scales through fusion of Landsat and MODIS imagery. *Remote Sensing of Environment*, 188, 9-25.

- [70] Di, L., Eugene, G. Y., Kang, L., Shrestha, R., & BAI, Y. Q. (2017). RF-CLASS: A remote-sensing-based flood crop loss assessment cyber-service system for supporting crop statistics and insurance decision-making. *Journal of integrative agriculture*, 16(2), 408-423.
- [71] Tseng, D., Wang, D., Chen, C., Miller, L., Song, W., Viers, J., ... & Goldberg, K. (2018, August). Towards automating precision irrigation: Deep Learning to infer local soil moisture conditions from synthetic aerial agricultural images. In *2018 IEEE 14th International Conference on Automation Science and Engineering* (pp. 284-291). IEEE.
- [72] PRIMA (2020), Results of the call prima section 1 2020 agrofood value chain ia, Disponible sur: <https://prima-med.org/results-of-the-call-prima-section-1-2020/> [Consulté le 29 septembre 2021].
- [73] PRIMA (2021), Why PRIMA, Disponible sur: <https://prima-med.org/about-us/prima-in-brief/> [Consulté le 29 septembre 2021].
- [74] The World Bank (2019). Morocco Digital and Climate Smart Agriculture Program (P170419), Disponible sur <http://documents1.worldbank.org/curated/en/648291567624827368/pdf/Concept-Stage-Program-Information-Documents-PID-Morocco-Digital-and-Climate-Smart-Agriculture-Program-P170419.pdf> [Consulté le 29 septembre 2021].
- [75] Zhou, W., Xu, Z., Ross, D., Dignan, J., Fan, Y., Huang, Y., ... & Li, B. (2019). Towards water-saving irrigation methodology: Field test of soil moisture profiling using flat thin mm-sized soil moisture sensors (MSMSs). *Sensors and Actuators B: Chemical*, 298, 126857.
- [76] Bacenetti, J., Palerri, L., Tartarini, S., Vesely, F. M., Foi, M., Movedi, E., ... & Confalonieri, R. (2020). May smart technologies reduce the environmental impact of nitrogen fertilization? A case study for paddy rice. *Science of The Total Environment*, 715, 136956.
- [77] B. Jabir, N. Falih, L. Rabhi, (2021). RNN- and CNN-based weed detection for crop improvement: An overview. *Foods and Raw Materials*, 2021, vol. 9, no. 2, pp. 387-396.
- [78] Welling, M. (2021). A first encounter with Machine Learning.
- [79] Bowles, M. (2019). *Machine Learning with Spark and Python: Essential Techniques for Predictive Analytics*. John Wiley & Sons. ISBN: 978-1-118-96174-2
- [80] Berry, M. W., Mohamed, A., & Yap, B. W. (Eds.). (2019). *Supervised and unsupervised learning for data science*. Springer Nature.
- [81] James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An introduction to statistical Learning* (Vol. 112, p. 18). New York: springer.
- [82] Churpek, M. M., Yuen, T. C., Winslow, C., Meltzer, D. O., Kattan, M. W., & Edelson, D. P. (2016). Multicenter comparison of machine Learning methods and conventional regression for predicting clinical deterioration on the wards. *Critical care medicine*, 44(2), 368.
- [83] Alfter, D. (2021). Exploring natural language processing for single-word and multi-word lexical complexity from a second language learner perspective.
- [84] Banan, A., Nasiri, A., & Taheri-Garavand, A. (2020). Deep learning-based appearance features extraction for automated carp species identification. *Aquacultural Engineering*, 89, 102053.
- [85] Albawi, S., Mohammed, T. A. and Al-Zawi, S. (2017) "Understanding of a convolutional neural network", In *2017 International Conference on Engineering and Technology (ICET)*, Antalya, Turkey, IEEE, pp. 1-6. DOI 10.1109/ICEngTechnol.2017.8308186.

- [86] Basha, S. S., Dubey, S. R., Pulabaigari, V. and Mukherjee, S. (2020) "Impact of fully connected layers on performance of convolutional neural networks for image classification", *Neurocomputing*, Vol. 378, pp. 112-119. ISSN 0925-2312. DOI 10.1016/j.neucom.2019.10.008.
- [87] Nguyen, T., Le, H., Quinn, T. P., Nguyen, T., Le, T. D., & Venkatesh, S. (2021). GraphDTA: Predicting drug–target binding affinity with graph neural networks. *Bioinformatics*, 37(8), 1140-1147.
- [88] Nita, C., & Vandewal, M. (2021, September). On the automatic text detection and recognition algorithms for maritime images. In *Artificial Intelligence and Machine Learning in Defense Applications III* (Vol. 11870, pp. 29-38). SPIE.
- [89] Noor, S. T., Asad, S. T., Khan, M. M., Gaba, G. S., Al-Amri, J. F., & Masud, M. (2021). Predicting the Risk of Depression Based on ECG Using RNN. *Computational Intelligence and Neuroscience*, 2021.
- [90] Tyagi, A. C. (2016). Towards a second green revolution. *Irrigation and Drainage*, 4(65), 388-389.
- [91] Gebbers, R., & Adamchuk, V. I. (2010). Precision agriculture and food security. *Science*, 327(5967), 828-831.
- [92] Guiné, R. P., Correia, P., Coelho, C., & Costa, C. A. (2021). The role of edible insects to mitigate challenges for sustainability. *Open Agriculture*, 6(1), 24-36.
- [93] FAO, (2009). *How to Feed the World in 2050*. Food and Agriculture Organization of the United Nations, Rome.
- [94] Brunetti, A., Buongiorno, D., Trotta, G. F., & Bevilacqua, V. (2018). Computer vision and deep learning techniques for pedestrian detection and tracking: A survey. *Neurocomputing*, 300, 17-33.
- [95] Mohamed, H. (2020). *La vérification automatique de parenté basée sur le visage* (Doctoral dissertation, Université laarbi tebessi tebessa).
- [96] Turkoglu, M. O., & Arican, T. (2017, September). Texture-based eyebrow recognition. In *2017 International Conference of the Biometrics Special Interest Group (BIOSIG)* (pp. 1-6). IEEE.
- [97] Hoiem, D., Divvala, S. K., & Hays, J. H. (2009). Pascal VOC challenge. *World Literature Today*, 24.
- [98] Lin, T. Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., ... & Zitnick, C. L. (2014, September). Microsoft coco: Common objects in context. In *European conference on computer vision* (pp. 740-755). Springer, Cham.
- [99] Lenc, K., & Vedaldi, A. (2015). R-cnn minus r. *arXiv preprint arXiv:1506.06981*.
- [100] Kaiming He, Xiangyu Zhang, Shaoqing Ren and Jian Sun, "Spatial pyramid pooling in deep convolutional networks for visual recognition", *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 37, no. 9, pp. 1904-1916, 2015.
- [101] Girshick, R. (2015). Fast r-cnn. In *Proceedings of the IEEE international conference on computer vision* (pp. 1440-1448).
- [102] Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 28.
- [103] K. He, X.Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," 2016, pp. 770–778.

- [104] Yan, L. C., Yoshua, B., & Geoffrey, H. (2015). Deep learning nature, 521 (7553), 436-444.
- [105] NING Shan, CHEN Haitao, ZHAO Qiuduo, WANG Yecheng. Detection of Pods and Stems in Soybean Based on IM-SSD+ACO Algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(12):182-190.
- [106] Mohanty SP, Hughes DP, Salathé M. Using Deep Learning for image-based plant disease detection. *Front Plant Sci.* 2016;7:1419.
- [107] T. T. Tran, J. W. Choi, T. T. H. Le, and J. W. Kim, “A comparative study of Deep CNN in forecasting and classifying the macronutrient deficiencies on development of tomato plant,” *Applied Sciences*, vol. 9, no. 8, article no. 1601, 2019.
- [108] Gao, Y., Liu, C., & Wu, X. (2021, December). Classification Method of Rape Root Swelling Disease Based on Convolution Neural Network. In *Journal of Physics: Conference Series* (Vol. 2138, No. 1, p. 012003). IOP Publishing.
- [109] Gu, Y. H., Yin, H., Jin, D., Park, J. H., & Yoo, S. J. (2021). Image-Based Hot Pepper Disease and Pest Diagnosis Using Transfer Learning and Fine-Tuning. *Frontiers in plant science*, 12, 724487.
- [110] Fuentes, A., Yoon, S., Lee, M. H., & Park, D. S. (2021). Improving Accuracy of Tomato Plant Disease Diagnosis Based on Deep Learning With Explicit Control of Hidden Classes. *Frontiers in plant science*, 12.
- [111] Zhang, R., Tian, Y., Zhang, J., Dai, S., Hou, X., Wang, J., & Guo, Q. (2021). Metric Learning for image-based flower cultivars identification. *Plant Methods*, 17(1), 1-14.
- [112] Ghazi, M. M., Yanikoglu, B., & Aptoula, E. (2017). Plant identification using Deep neural networks via optimization of transfer Learning parameters. *Neurocomputing*, 235, 228-235.
- [113] Etienne, A., Ahmad, A., Aggarwal, V., & Saraswat, D. (2021). Deep Learning-Based Object Detection System for Identifying Weeds Using UAS Imagery. *Remote Sensing*, 13(24), 5182.
- [114] Kartal, S. (2021). Comparison of semantic segmentation algorithms for the estimation of botanical composition of clover-grass pastures from RGB images. *Ecological Informatics*, 66, 101467.
- [115] Xu, K., Zhu, Y., Cao, W., Jiang, X., Jiang, Z., Li, S., & Ni, J. (2021). Multi-Modal Deep Learning for Weeds Detection in Wheat Field Based on RGB-D Images. *Frontiers in plant science*, 12, 732968-732968.
- [116] Dos Santos Ferreira, A., Freitas, D. M., da Silva, G. G., Pistori, H., & Folhes, M. T. (2017). Weed detection in soybean crops using ConvNets. *Computers and Electronics in Agriculture*, 143, 314-324.
- [117] Farooq, A., Hu, J., & Jia, X. (2018). Analysis of spectral bands and spatial resolutions for weed classification via Deep convolutional neural network. *IEEE Geoscience and Remote Sensing Letters*, 16(2), 183-187.
- [118] Lammie, C., Olsen, A., Carrick, T., & Azghadi, M. R. (2019). Low-Power and High-Speed Deep FPGA Inference Engines for Weed Classification at the Edge. *IEEE Access*, 7, 51171-51184.
- [119] Sant'Ana, D. A., Pache, M. C. B., Martins, J., Astolfi, G., Soares, W. P., de Melo, S. L. N., ... & Pistori, H. (2022). Computer vision system for superpixel classification and segmentation of sheep. *Ecological Informatics*, 101551.

- [120] Sarwar, F., Griffin, A., Periasamy, P., Portas, K., & Law, J. (2018, November). Detecting and counting sheep with a convolutional neural network. In 2018 15th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS) (pp. 1-6). IEEE.
- [121] Neethirajan, S. (2022). Automated tracking systems for the assessment of farmed poultry. *Animals*, 12(3), 232.
- [122] S. A. Jwade, A. Guzzomi, and A. Mian, "On farm automatic sheep breed classification using Deep learning," *Computers and Electronics in Agriculture*, vol. 167, Article 105055, 2019.
- [123] Y. Qiao, M. Truman, and S. Sukkarieh, "Cattle segmentation and contour extraction based on Mask R-CNN for precision livestock farming," *Computers and Electronics in Agriculture*, vol. 165, article no. 104958, 2019.
- [124] Wutke, M., Heinrich, F., Das, P. P., Lange, A., Gentz, M., Traulsen, I., ... & Gültas, M. (2021). Detecting Animal Contacts—A Deep Learning-Based Pig Detection and Tracking Approach for the Quantification of Social Contacts. *Sensors*, 21(22), 7512.
- [125] Bhujel, A., Arulmozhi, E., Moon, B. E., & Kim, H. T. (2021). Deep-Learning-Based Automatic Monitoring of Pigs' Physico-Temporal Activities at Different Greenhouse Gas Concentrations. *Animals*, 11(11), 3089.
- [126] N. Kussul, M. Lavreniuk, S. Skakun and A. Shelestov, "Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data," in *IEEE Geoscience and Remote Sensing Letters*, vol. 14, no. 5, pp. 778-782, May 2017, doi: 10.1109/LGRS.2017.2681128.
- [127] Gaetano, R., Ienco, D., Ose, K., & Cresson, R. (2018). A two-branch CNN architecture for land cover classification of PAN and MS imagery. *Remote Sensing*, 10(11), 1746.
- [128] Liang, L., Meyarian, A., Yuan, X., Runkle, B. R., Mihaila, G., Qin, Y., ... & Rigby, J. R. (2021). The first fine-resolution mapping of contour-levee irrigation using Deep Bi-Stream convolutional neural networks. *International Journal of Applied Earth Observation and Geoinformation*, 105, 102631.
- [129] Islam, M. P., & Yamane, T. (2021). HortNet417v1 A Deep-Learning Architecture for the Automatic Detection of Pot-Cultivated Peach Plant Water Stress. *Sensors*, 21(23), 7924.
- [130] Granata, F., & Di Nunno, F. (2021). Forecasting evapotranspiration in different climates using ensembles of recurrent neural networks. *Agricultural Water Management*, 255, 107040.
- [131] Sung, J. H., Ryu, Y., & Chung, E. S. (2020). Estimation of water-use rates based on hydro-meteorological variables using Deep belief network. *Water*, 12(10), 2700.
- [132] Bresilla, K., Perulli, G. D., Boini, A., Morandi, B., Corelli Grappadelli, L., & Manfrini, L. (2019). Single-shot convolution neural networks for real-time fruit detection within the tree. *Frontiers in plant science*, 10, 611.
- [133] Chung, D. T. P., & Van Tai, D. (2019, October). A fruits recognition system based on a modern Deep Learning technique. In *Journal of physics: conference series* (Vol. 1327, No. 1, p. 012050). IOP Publishing.
- [134] Malinovský, V. (2021) "Predicting Trends in Cereal Production in the Czech Republic by Means of Neural Networks", *AGRIS on-line Papers in Economics and Informatics*, Vol. 13, No. 1, pp. 87-103. ISSN 1804-1930. DOI 10.7160/aol.2021.130107.
- [135] Gill, M. K., Asefa, T., Kemblowski, M. W., & McKee, M. (2006). Soil moisture prediction using support vector machines 1. *JAWRA Journal of the American Water Resources Association*, 42(4), 1033-1046.

- [136] Adnan, M., Adnan, R. M., Liu, S., Saifullah, M., Latif, Y., & Iqbal, M. (2021). Prediction of relative humidity in a high elevated basin of western Karakoram by using different machine Learning models. *Weather Forecasting*, 59.
- [137] Kasinathan, T., Singaraju, D., & Uyyala, S. R. (2021). Insect classification and detection in field crops using modern machine Learning techniques. *Information Processing in Agriculture*, 8(3), 446-457.
- [138] Guillén-Navarro, M. A., Martínez-España, R., Llanes, A., Bueno-Crespo, A., & Cecilia, J. M. (2020). A Deep Learning model to predict lower temperatures in agriculture. *Journal of Ambient Intelligence and Smart Environments*, 12(1), 21-34.
- [139] Muhammad, W., Ullah, I., & Ashfaq, M. (2020). An Introduction to Deep Convolutional Neural Networks With Keras. In *Machine Learning and Deep Learning in Real-Time Applications* (pp. 231-272). IGI Global.
- [140] Jauro, F., Chiroma, H., Gital, A. Y., Almutairi, M., Shafi'i, M. A., & Abawajy, J. H. (2020). Deep Learning architectures in emerging cloud computing architectures: Recent development, challenges and next research trend. *Applied Soft Computing*, 96, 106582.
- [141] Ott, J., Pritchard, M., Best, N., Linstead, E., Curcic, M., & Baldi, P. (2020). A Fortran-Keras Deep Learning bridge for scientific computing. *Scientific Programming*, 2020.
- [142] Ngo-Samnick, E. L., & Fournier, S. (2015). Agriculture durable et sécurité alimentaire: défis du 21ème siècle. *Liaison Energie Francophonie*, (100), 81-86.
- [143] Martin-Clouaire, R. (2017). Modelling operational decision-making in agriculture. *Agricultural Sciences*, 8(07), 527-544.
- [144] Badarinath, K. V. S., Chand, T. K., & Prasad, V. K. (2006). Agriculture crop residue burning in the Indo-Gangetic Plains—a study using IRS-P6 AWiFS satellite data. *Current Science*, 1085-1089.
- [145] Pouya, M. B., Diebre, R., Rambaldi, G., Zomboudry, G., Barry, F., Sedogo, M., & Lompo, F. (2020). Analyse comparative de l'agriculture de précision incluant l'utilisation de la technologie drone et de l'agriculture classique en matière de production de riz et de revenu des agriculteurs au Burkina Faso. CTA Technical Report.
- [146] McNairn, H., & Brisco, B. (2004). The application of C-band polarimetric SAR for agriculture: A review. *Canadian Journal of Remote Sensing*, 30(3), 525-542.
- [147] Vadivambal, R., & Jayas, D. S. (2011). Applications of thermal imaging in agriculture and food industry—a review. *Food and bioprocess technology*, 4(2), 186-199.
- [148] Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine Learning in agriculture: A review. *Sensors*, 18(8), 2674.
- [149] Labat, D., Ababou, R., & Mangin, A. (2000). Rainfall–runoff relations for karstic springs. Part II: continuous wavelet and discrete orthogonal multiresolution analyses. *Journal of hydrology*, 238(3-4), 149-178.
- [150] Hoekman, D. H., & Vissers, M. A. (2003). A new polarimetric classification approach evaluated for agricultural crops. *IEEE Transactions on Geoscience and Remote Sensing*, 41(12), 2881-2889.
- [151] Leroux, L. (2015). Suivi et caractérisation des dynamiques de la production agricole en Afrique de l'ouest par télédétection à moyenne résolution spatiale (Doctoral dissertation, AgroParisTech).
- [152] Karkacier, O., Goktolga, Z. G., & Cicek, A. (2006). A regression analysis of the effect of energy use in agriculture. *Energy Policy*, 34(18), 3796-3800.
- [153] Kamlaris, A., & Prenafeta-Boldú, F. X. (2018). Deep Learning in agriculture: A survey. *Computers and electronics in agriculture*, 147, 70-90.

- [154] Jabir, B., Falih, N., & Rahmani, K. (2021). Accuracy and Efficiency Comparison of Object Detection Open-Source Models. *International Journal of Online & Biomedical Engineering*, 17(5).
- [155] S. Pinitkan and N. Wisitpongphan, "Abnormal Activity Detection and Notification Platform for Real-Time Ad Hoc Network," *International Journal of Online & Biomedical Engineering*, vol. 16, no 15, 2020.
- [156] M. Tan, R. Pang, and Q. V. Le, "Efficientdet: Scalable and efficient object detection," in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. 2020. p. 10781-10790.
- [157] M. Tan and Q. Le, "Efficientnet: Rethinking model scaling for convolutional neural networks," in *International Conference on Machine Learning*. PMLR, 2019. p. 6105-6114.
- [158] S. Ren, K. He, R. Girshick, and J. Sun, "Faster r-cnn: Towards real-time object detection with region proposal networks," *arXiv preprint arXiv:1506.01497*, 2015.
- [159] J. Pang, K. Chen, J. Shi, H. Feng, W. Ouyang, and D. Lin, "Libra r-cnn: Towards balanced Learning for object detection," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2019. p. 821-830.
- [160] V. Margapuri and M. Neilsen, "Seed Phenotyping on Neural Networks using Domain Randomization and Transfer Learning," *arXiv preprint arXiv:2012.13259*, 2020.
- [161] L. Boukhris, et al., "Tailored Deep Learning based Architecture for Smart Agriculture," in *2020 International Wireless Communications and Mobile Computing (IWCMC)*. IEEE, 2020. p. 964-969.
- [162] Y. Saleh and G. Issa, "Arabic Sign Language Recognition through Deep Neural Networks Fine-Tuning," *International Journal of Online & Biomedical Engineering*, vol. 15, no 05, 2020.
- [163] S. Hinterstoisser, S. Pauly, O. Heibel, H. Martina, M., & Bokeloh, M. (2019). An annotation saved is an annotation earned: Using fully synthetic training for object detection. In *Proceedings of the IEEE/CVF international conference on computer vision workshops* (pp. 0-0).
- [164] R. Yu, S. Zheng, A. Anandkumar, and Y. Yue, "Long-term forecasting using tensor-train rnns," *Arxiv*, 2017.
- [165] Inoue, H. (2018). Data augmentation by pairing samples for images classification. *arXiv preprint arXiv:1801.02929*.
- [166] Rungsuptaweekoon, K., Visoottiviseth, V., & Takano, R. (2017, November). Evaluating the power efficiency of Deep Learning inference on embedded GPU systems. In *2017 2nd International Conference on Information Technology (INCIT)* (pp. 1-5). IEEE.
- [167] Asano, S., Maruyama, T., & Yamaguchi, Y. (2009, August). Performance comparison of FPGA, GPU and CPU in image processing. In *2009 international conference on field programmable logic and applications* (pp. 126-131). IEEE.
- [168] Y. Li, K. Yin, J. Liang, C. Wang, and G. Yin, "A Multi-task Joint Framework for Real-time Person Search," *arXiv preprint arXiv:2012.06418*, 2020.
- [169] Efthimiadou, A. P., Karkanis, A. C., Bilalis, D. J., & Efthimiadis, P. (2009). The phenomenon of crop-weed competition; a problem or a key for sustainable weed management?. *Journal of Food, Agriculture & Environment*, 7(2), 861-868.
- [170] Heap, I., & Duke, S. O. (2018). Overview of glyphosate-resistant weeds worldwide. *Pest management science*, 74(5), 1040-1049.
- [171] Harker, K. N., & O'Donovan, J. T. (2013). Recent weed control, weed management, and integrated weed management. *Weed Technology*, 27(1), 1-11.

- [172] Jiao, L., Zhang, F., Liu, F., Yang, S., Li, L., Feng, Z., & Qu, R. (2019). A survey of Deep learning-based object detection. IEEE access, 7, 128837-128868.
- [173] Kumar, G., & Bhatia, P. K. (2014, February). A detailed review of feature extraction in image processing systems. In 2014 Fourth international conference on advanced computing & communication technologies (pp. 5-12). IEEE.
- [174] Du, X., Cai, Y., Wang, S., & Zhang, L. (2016, November). Overview of Deep learning. In 2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC) (pp. 159-164). IEEE., X., Cai, Y., Wang, S., & Zhang, L. (2016, November). Overview of Deep learning. In 2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC) (pp. 159-164). IEEE.
- [175] Jabir, B., Falih, N., Sarih, A., & Tannouche, A. (2021). A strategic analytics using convolutional neural networks for weed identification in sugar beet fields. *AGRIS on-line Papers in Economics and Informatics*, 13(1), 49-57.
- [176] Jabir, B., & Falih, N. (2022). Deep learning-based decision support system for weeds detection in wheat fields. *International Journal of Electrical and Computer Engineering*, 12(1), 816.
- [177] Jabir, B., & Falih, N. (2021). Dropout, a basic and effective regularization method for a Deep Learning model: a case study. *Indonesian Journal of Electrical Engineering and Computer Science*, 24(2), 1009-1016.
- [178] Bisong, E. (2019). Tensorflow 2.0 and keras. In *Building Machine Learning and Deep Learning Models on Google Cloud Platform* (pp. 347-399). Apress, Berkeley, CA.
- [179] Karanam, S. R., Srinivas, Y., & Krishna, M. V. (2020). Study on image processing using Deep Learning techniques. *Materials Today: Proceedings*.
- [180] Ketkar, N., & Santana, E. (2017). *Deep Learning with Python* (Vol. 1). Berkeley: Apress.
- [181] M. Ju, et al., "The application of improved YOLO V3 in multi-scale target detection," *Applied Sciences*, 9(18), 3775, 2019.
- [182] Y. Han and K. Lee, "Acoustic scene classification using convolutional neural network and multiple-width frequency-delta data augmentation," *arXiv preprint arXiv:1607.02383*, 2016.
- [183] X. Long, et al., "PP-YOLO: An effective and efficient implementation of object detector," *arXiv preprint arXiv:2007.12099*, 2020.
- [184] H. Wang, et al., "Deep Learning based target detection algorithm for motion capture applications," In *Journal of Physics: Conference Series*, Vol. 1682, No. 1, p. 012032. IOP Publishing, 2020.
- [185] H. Rezatofghi, et al., "Generalized intersection over union: A metric and a loss for bounding box regression," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 658-666, 2019.
- [186] Ò. Lorente, I. Riera, and A. Rana, A. "Image Classification with Classic and Deep Learning Techniques," . *arXiv preprint arXiv:2105.04895*, 2021.
- [187] S.-C. Kim, P. Ray, and S. R. Salkuti, "Islanding detection in a distribution network with distributed generators using signal processing techniques," *International Journal of Power Electronics and Drive Systems*, vol. 11, no 4, pp. 2099~2106, 2020, doi: 10.11591/ijpeds.v11.i4.pp2099-2106.
- [188] A. RÁCZ, D. Bajusz, and K. Héberger, "Effect of dataset Size and Train/Test Split Ratios in QSAR/QSPR Multiclass Classification," *Molecules*, vol. 26, n. 4, p. 1111, févr. 2021, doi: 10.3390/molecules26041111.

- [189] C. Moodley, B. Sephton, V. Rodríguez-Fajardo, and A. Forbes, "Deep Learning early stopping for non-degenerate ghost imaging," *Scientific Reports*, vol. 11, n. 1, p. 8561, déc. 2021, doi: 10.1038/s41598-021-88197-5.
- [190] S. Shrestha, A. Alsadoon, P. W. C. Prasad, I. Seher, and O. H. Alsadoon, "A novel solution of using Deep Learning for prostate cancer segmentation: enhanced batch normalization," *Multimed Tools Appl*, vol. 80, no 14, pp. 21293-21313, juin 2021.
- [191] R. L. Kumar, J. Kakarla, B. V. Isunuri, et M. Singh, "Multi-class brain tumor classification using residual network and global average pooling," *Multimed Tools Appl*, vol. 80, no 9, p. 13429-13438, avr. 2021, doi: 10.1007/s11042-020-10335-4.
- [192] H. Q. Nguyen, et al., "Low cost real-time system monitoring using Raspberry Pi," in 2015 Seventh International Conference on Ubiquitous and Future Networks, pp. 857-859. IEEE, 2015.
- [193] A. Imteaj, et al., "IoT based autonomous percipient irrigation system using raspberry Pi," in 2016 19th International Conference on Computer and Information Technology (ICCIT), pp. 563-568. IEEE, 2016.
- [194] R. B. Anire, et al., "Environmental wireless sensor network using raspberry Pi 3 for greenhouse monitoring system," in 2017 IEEE 9th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM), pp. 1-5. IEEE, 2017.
- [195] Pulido, C., Solaque, L., & Velasco, N. (2017). Weed recognition by SVM texture feature classification in outdoor vegetable crop images. *Ingeniería e Investigación*, 37(1), 68-74.
- [196] Forero, M. G., Herrera-Rivera, S., Ávila-Navarro, J., Franco, C. A., Rasmussen, J., & Nielsen, J. (2018, November). Color classification methods for perennial weed detection in cereal crops. In *Iberoamerican Congress on Pattern Recognition* (pp. 117-123). Springer, Cham.
- [197] Olsen, A., Han, S., Calvert, B., Ridd, P., & Kenny, O. (2015, November). In situ leaf classification using histograms of oriented gradients. In *2015 International Conference on Digital Image Computing: Techniques and Applications (DICTA)* (pp. 1-8). IEEE.
- [198] Muppala, C., & Guruviah, V. (2020). Machine vision detection of pests, diseases and weeds: A review. *J. Phytol.*, 12, 9-19.
- [199] Milioto, A., Lottes, P., & Stachniss, C. (2018, May). Real-time semantic segmentation of crop and weed for precision agriculture robots leveraging background knowledge in CNNs. In *2018 IEEE international conference on robotics and automation (ICRA)* (pp. 2229-2235). IEEE.
- [200] Mahajan, A., & Chaudhary, S. (2019, June). Categorical image classification based on representational Deep network (RESNET). In *2019 3rd International conference on Electronics, Communication and Aerospace Technology (ICECA)* (pp. 327-330). IEEE.
- [201] Hitawala, S. (2018). Evaluating ResNeXt Model Architecture for Image Classification. arXiv preprint arXiv:1805.08700.
- [202] Li, X., Wang, L., & Sung, E. (2004, October). Multilabel SVM active Learning for image classification. In *2004 International Conference on Image Processing, 2004. ICIP'04.* (Vol. 4, pp. 2207-2210). IEEE.
- [203] Jabir, Brahim and Nouredine Falih. "A New Hybrid Model of Deep Learning ResNeXt-SVM for Weed Detection: Case Study." *IJIIT* vol.18, no.2 2022: pp.1-18. <http://doi.org/10.4018/IJIIT.296269>

- [204] Sun, C., Shrivastava, A., Singh, S., & Gupta, A. (2017). Revisiting unreasonable effectiveness of data in Deep Learning era. In Proceedings of the IEEE international conference on computer vision (pp. 843-852).
- [205] Nakkiran, P., Kaplun, G., Bansal, Y., Yang, T., Barak, B., & Sutskever, I. (2019). Deep double descent: Where bigger models and more data hurt. arXiv preprint arXiv:1912.02292.
- [206] Rice, L., Wong, E., & Kolter, Z. (2020, November). Overfitting in adversarially robust Deep learning. In International Conference on Machine Learning (pp. 8093-8104). PMLR.
- [207] Van Tulder, G., & de Bruijne, M. (2015, October). Why does synthesized data improve multi-sequence classification?. In International Conference on Medical Image Computing and Computer-Assisted Intervention (pp. 531-538). Springer, Cham.
- [208] Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for Deep learning. *Journal of Big data*, 6(1), 1-48.
- [209] Jampani, R., Xu, F., Wu, M., Perez, L. L., Jermaine, C., & Haas, P. J. (2008, June). Mcdb: a monte carlo approach to managing uncertain data. In Proceedings of the 2008 ACM SIGMOD international conference on Management of data (pp. 687-700).
- [210] Sawicki, M. (2012). SEDfit: Software for spectral energy distribution fitting of photometric data. *Publications of the Astronomical Society of the Pacific*, 124(921), 1208.
- [211] Liu, X., Gherbi, A., Wei, Z., Li, W., & Cheriet, M. (2020). Multispectral image reconstruction from color images using enhanced variational autoencoder and generative adversarial network. *IEEE Access*, 9, 1666-1679.
- [212] Fuhl, W., Rong, Y., & Kasneci, E. (2021, January). Fully convolutional neural networks for raw eye tracking data segmentation, generation, and reconstruction. In 2020 25th International Conference on Pattern Recognition (ICPR) (pp. 142-149). IEEE.
- [213] Ponti, M. A., Ribeiro, L. S. F., Nazare, T. S., Bui, T., & Collomosse, J. (2017, October). Everything you wanted to know about Deep Learning for computer vision but were afraid to ask. In 2017 30th SIBGRAPI conference on graphics, patterns and images tutorials (SIBGRAPI-T) (pp. 17-41). IEEE.
- [214] Feng, J., Feng, X., Chen, J., Cao, X., Zhang, X., Jiao, L., & Yu, T. (2020). Generative adversarial networks based on collaborative Learning and attention mechanism for hyperspectral image classification. *Remote Sensing*, 12(7), 1149.
- [215] Chuck, C., Laskey, M., Krishnan, S., Joshi, R., Fox, R., & Goldberg, K. (2017, August). Statistical data cleaning for Deep Learning of automation tasks from demonstrations. In 2017 13th IEEE Conference on Automation Science and Engineering, pp. 1142-1149.
- [216] Johnson, J. M., & Khoshgoftaar, T. M. (2020). The effects of data sampling with Deep Learning and highly imbalanced Big data. *Information Systems Frontiers*, 22(5), 1113-1131.
- [217] Osband, I., Aslanides, J., & Cassirer, A. (2018). Randomized prior functions for Deep reinforcement learning. arXiv preprint arXiv:1806.03335.
- [218] Thara, D. K., PremaSudha, B. G., & Xiong, F. (2019). Auto-détection of epileptic seizure events using Deep neural network with different feature scaling techniques. *Pattern Recognition Letters*, 128, 544-550.
- [219] Huang, L., Zhou, Y., Zhu, F., Liu, L., & Shao, L. (2019). Iterative normalization: Beyond standardization towards efficient whitening. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (pp. 4874-4883).

- [220] Pal, K. K., & Sudeep, K. S. (2016, May). Preprocessing for image classification by convolutional neural networks. In 2016 IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (pp. 1778-1781). IEEE.
- [221] Shi, H., Li, H., Zhang, D., Cheng, C., & Cao, X. (2018). An efficient feature generation approach based on Deep Learning and feature selection techniques for traffic classification. *Computer Networks*, 132, 81-98.
- [222] Doreswamy, D., & Nigus, M. (2020, March). Feature Selection Methods for Household Food Insecurity Classification. In 2020 International Conference on Computer Science, Engineering and Applications (ICCSEA) (pp. 1-7). IEEE.
- [223] Zhong, B., Xing, X., Luo, H., Zhou, Q., Li, H., Rose, T., & Fang, W. (2020). Deep learning-based extraction of construction procedural constraints from construction regulations. *Advanced Engineering Informatics*, 43, 101003.
- [224] Schreiber, J. (2017). Pomegranate: fast and flexible probabilistic modeling in python. *The Journal of Machine Learning Research*, 18(1), 5992-5997.
- [225] Hao, J., & Ho, T. K. (2019). Machine Learning made easy: a review of scikit-learn package in python programming language. *Journal of Educational and Behavioral Statistics*, 44(3), 348-361.
- [226] Kao, Y. T., Zahara, E., & Kao, I. W. (2008). A hybridized approach to data clustering. *Expert Systems with Applications*, 34(3), 1754-1762.
- [227] Mahesh, B. (2020). Machine Learning Algorithms-A Review. *International Journal of Science and Research (IJSR)*. [Internet], 9, 381-386.
- [228] Browne, M. W. (2000). Cross-validation methods. *Journal of mathematical psychology*, 44(1), 108-132.
- [229] Li, T., Levina, E., & Zhu, J. (2020). Network cross-validation by edge sampling. *Biometrika*, 107(2), 257-276.
- [230] Handelman, G. S., Kok, H. K., Chandra, R. V., Razavi, A. H., Huang, S., Brooks, M., ... & Asadi, H. (2019). Peering into the black box of artificial intelligence: evaluation metrics of machine Learning methods. *American Journal of Roentgenology*, 212(1), 38-43.
- [231] Choudhary, R., & Gianey, H. K. (2017, December). Comprehensive review on supervised machine Learning algorithms. In 2017 International Conference on Machine Learning and Data Science (MLDS) (pp. 37-43). IEEE.
- [232] Pavlyshenko, B. M. (2016, August). Linear, machine Learning and probabilistic approaches for time series analysis. In 2016 IEEE First International Conference on Data Stream Mining & Processing (DSMP) (pp. 377-381). IEEE.
- [233] Ouyang, F. S., Guo, B. L., Ouyang, L. Z., Liu, Z. W., Lin, S. J., Meng, W., ... & Yang, S. M. (2019). Comparison between linear and nonlinear machine-learning algorithms for the classification of thyroid nodules. *European journal of radiology*, 113, 251-257.
- [234] Ranjan, R., Sankaranarayanan, S., Bansal, A., Bodla, N., Chen, J. C., Patel, V. M., ... & Chellappa, R. (2018). Deep Learning for understanding faces: Machines may be just as good, or better, than humans. *IEEE Signal Processing Magazine*, 35(1), 66-83.
- [235] Narendran, D. J., Abilash, R., & Charulatha, B. S. (2021). Exploration of Classification Algorithms for Divorce Prediction. In *Proceedings of International Conference on Recent Trends in Machine Learning, IoT, Smart Cities and Applications* (pp. 291-303). Springer, Singapore.

- [236] O'Shea, A., Lightbody, G., Boylan, G., & Temko, A. (2018, July). Investigating the impact of CNN depth on neonatal seizure detection performance. In 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) (pp. 5862-5865). IEEE.
- [237] Zhou, D., Tian, F., Tian, X., Sun, L., Huang, X., Zhao, F., ... & Li, X. (2020). Diagnostic evaluation of a Deep Learning model for optical diagnosis of colorectal cancer. *Nature communications*, 11(1), 1-9.
- [238] Hoiem, D., Gupta, T., Li, Z., & Shlapentokh-Rothman, M. (2021, July). Learning Curves for Analysis of Deep Networks. In *International Conference on Machine Learning* (pp. 4287-4296). PMLR.
- [239] Reimers, N., & Gurevych, I. (2017). Optimal hyperparameters for Deep lstm-networks for sequence labeling tasks. *arXiv preprint arXiv:1707.06799*.
- [240] Kotsiantis, S. B., Zaharakis, I. D., & Pintelas, P. E. (2006). Machine learning: a review of classification and combining techniques. *Artificial Intelligence Review*, 26(3), 159-190.
- [241] Jahrer, M., Töschler, A., & Legenstein, R. (2010, July). Combining predictions for accurate recommender systems. In *Proceedings of the 16th ACM SIGKDD international conference on Knowledge discovery and data mining* (pp. 693-702).
- [242] Kotsiantis, S. B., Zaharakis, I., & Pintelas, P. (2007). Supervised machine learning: A review of classification techniques. *Emerging artificial intelligence applications in computer engineering*, 160(1), 3-24.
- [243] Mi, X., Zou, F., & Zhu, R. (2019). Bagging and Deep Learning in optimal individualized treatment rules. *Biometrics*, 75(2), 674-684.
- [244] Zhang, Z., Chen, B., Sun, J., & Luo, Y. (2021). A bagging dynamic Deep Learning network for diagnosing COVID-19. *Scientific Reports*, 11(1), 1-15.
- [245] Hothorn, T., & Lausen, B. (2003). Double-bagging: combining classifiers by bootstrap aggregation. *Pattern Recognition*, 36(6), 1303-1309.
- [246] Deng, L., Yu, D., & Platt, J. (2012, March). Scalable stacking and Learning for building Deep architectures. In *2012 IEEE International conference on Acoustics, speech and signal processing (ICASSP)* (pp. 2133-2136). IEEE.
- [247] Li, S., Song, W., Fang, L., Chen, Y., Ghamisi, P., & Benediktsson, J. A. (2019). Deep Learning for hyperspectral image classification: An overview. *IEEE Transactions on Geoscience and Remote Sensing*, 57(9), 6690-6709.
- [248] Deng, L., & Liu, Y. (2018). A joint introduction to natural language processing and to Deep learning. In *Deep Learning in natural language processing* (pp. 1-22). Springer, Singapore.
- [249] Nassif, A. B., Shahin, I., Attili, I., Azzeh, M., & Shaalan, K. (2019). Speech recognition using Deep neural networks: A systematic review. *IEEE access*, 7, 19143-19165.
- [250] Kowsari, K., Brown, D. E., Heidarysafa, M., Meimandi, K. J., Gerber, M. S., & Barnes, L. E. (2017, December). Hdltext: Hierarchical Deep Learning for text classification. In *2017 16th IEEE international conference on machine Learning and applications (ICMLA)* (pp. 364-371). IEEE.
- [251] Agarap, A. F. M. (2018, February). A neural network architecture combining gated recurrent unit (GRU) and support vector machine (SVM) for intrusion detection in network traffic data. In *Proceedings of the 2018 10th international conference on machine Learning and computing* (pp. 26-30).

- [252] Alalshekmubarak, A., & Smith, L. S. (2013, March). A novel approach combining recurrent neural network and support vector machines for time series classification. In 2013 9th International Conference on Innovations in Information Technology (IIT) (pp. 42-47). IEEE.
- [253] Kim, M. S., Lee, G. Y., & Kim, H. G. (2021). Exotic Weed Image Recognition System Based on ResNeXt Model. *Journal of Korea Multimedia Society*, 24(6), 745-752.
- [254] Vogelsang, D. C., & Erickson, B. J. (2020). Magician's corner: 6. TensorFlow and TensorBoard.
- [255] Olsen, A., Konovalov, D. A., Philippa, B., Ridd, P., Wood, J. C., Johns, J., & White, R. D. (2019). DeepWeeds: A multiclass weed species image dataset for Deep learning. *Scientific reports*, 9(1), 1-12.
- [256] Xie, S., Girshick, R., Dollár, P., Tu, Z., & He, K. (2017). Aggregated residual transformations for Deep neural networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1492-1500).
- [257] Bansal, N., Chen, X., & Wang, Z. (2018). Can we gain more from orthogonality regularizations in training Deep CNNs?. *arXiv preprint arXiv:1810.09102*.
- [258] Vapnik, V., Guyon, I., & Hastie, T. (1995). Support vector machines. *Mach. Learn*, 20(3), 273-297.
- [259] Asad, M. H., & Bais, A. (2019). Weed detection in canola fields using maximum likelihood classification and Deep convolutional neural network. *Information Processing in Agriculture*.